

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 LA COGNITION POUR ESTIMER LA QUALITÉ DE TRANSMISSION DANS LES RÉSEAUX OPTIQUES	5
1.1 Estimation de la qualité de transmission.....	5
1.2 Le projet CHRON et l’outil E-Tool.....	8
1.3 L’apprentissage machine	9
1.4 Réseaux optiques cognitifs	11
1.5 Conclusion	13
CHAPITRE 2 DÉVELOPPEMENT DU MODÈLE DE CALCUL DES PARAMÈTRES DE QUALITÉ DE TRANSMISSION D’UNE LIAISON OPTIQUE	15
2.1 Notions de connexions optiques et de liaisons optiques.....	15
2.1.1 Caractéristiques de la transmission optique.....	16
2.2 Effets linéaires dans une fibre optique.....	22
2.3 Effets non linéaires dans une fibre optique.....	25
2.3.1 Les effets non linéaires dans les liaisons optiques à compensation électronique de dispersion.....	26
2.4 Qualité de transmission optique et le modèle de bruit gaussien additif.....	30
2.4.1 Formule analytique de la qualité de transmission.....	30
2.5 Conclusion	33
CHAPITRE 3 ESTIMATION DE LA QOT DE CONNEXIONS OPTIQUES DANS LES RÉSEAUX WDM COHÉRENTS À COMPENSATION ÉLECTRONIQUE DE DISPERSION À L’AIDE DE TECHNIQUES D’APPRENTISSAGE MACHINE.....	35
3.1 Génération de données synthétiques de BER sur MATLAB.....	36
3.2 Validation des données synthétiques	39
3.2.1 Validation d’une liaison WDM 112 Gbit/s à 4 canaux avec l’outil web <i>NLIN Wizard</i>	39
3.2.2 Comparaison avec l’OSNR mesuré sur une liaison WDM 112 Gbit/s à 4 canaux avec compensation optique de la dispersion avec l’outil VPItransmissionMaker	42
3.2.3 Comparaison avec l’OSNR obtenu à partir de la formule analytique de calcul d’OSNR final sur une liaison optique	46
3.3 Classification de connexions optiques à l’aide de la cognition	47
3.3.1 Les méthodes d’apprentissage machine dans les réseaux optiques	48
3.3.2 Les méthodes de validation dans les processus de classification et de prédiction	50
3.3.3 Les techniques d’apprentissage machine étudiées.....	53

3.3.4	Choix d'algorithme de classification et de prédiction de la QoT selon les critères de performance	63
3.4	Conclusion	65
CHAPITRE 4 RÉSULTATS ET DISCUSSION		67
4.1	Analyse de performance de chacune des techniques d'apprentissage machine	67
4.2	Comparaison des résultats des différentes méthodes.....	69
4.3	Conclusion	74
CONCLUSION		77
RECOMMANDATIONS		81
LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES		95

LISTE DES TABLEAUX

	Page
Tableau 3.1	OSNR en fonction de la distance de transmission.....46
Tableau 3.2	Matrice de confusion adaptée de Alpaydin (2010).....51

LISTE DES FIGURES

	Page
Figure 2.1	Exemple de connexions optiques (λ_1, λ_2)16
Figure 2.2	Diagramme simplifié d'un système de communication.....17
Figure 2.3	Circuit d'un transmetteur PSK Adaptée de Infinera (2016)18
Figure 2.4	Circuit d'un transmetteur PM-QPSK,.....19
Figure 2.5	Récepteur cohérent avec DSP20
Figure 2.6	Auto-interférence de canal.....27
Figure 2.7	Interférence de canal croisée.....27
Figure 2.8	Interférence multi-canal28
Figure 3.1	Schéma global de l'étude36
Figure 3.2	Paramètres de la fibre en entrée sur l'outil NLIN Wizard41
Figure 3.3	Paramètres de la transmission en entrée sur le NLIN Wizard41
Figure 3.4	Puissance de bruit d'interférences non linéaires42
Figure 3.5	Puissance de l'émission spontanée amplifiée et OSNR en bleu42
Figure 3.6	OSNR reçu en fonction de la distance sur une liaison.....44
Figure 3.7	OSNR reçu en fonction de la distance sur VPI.....45
Figure 3.8	Boucle cognitive48
Figure 3.9	Erreur de validation en fonction de K avant la mise à l'échelle55
Figure 3.10	Erreur de validation en fonction de K.....56
Figure 3.11	Marge d'hyperplan.....57
Figure 3.12	Présentation d'un échantillon de données avec les étiquettes.....59
Figure 3.13	Classification d'un échantillon de connexions optiques60
Figure 3.14	Arbre de classification d'un échantillon de 200 connexions optiques.....63

Figure 4.1	Erreur de classification hors sac	68
Figure 4.2	Matrice de confusion de la technique K-NN	70
Figure 4.3	Matrice de confusion de la technique RF	71
Figure 4.4	Matrice de confusion de la technique SVM.....	72
Figure 4.5	Courbes ROC de la technique SVM.....	74

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

ADC	Analog to Digital Converter
ASE	Amplified Spontaneous Emission
AUC	Area under the curve
AWGN	Additive White Gaussian Noise
BER	Bit Error Rate
BPSK	Binary Phase Shift Keying
CART	Classification and regression trees
CBR	Case-Based Reasoning
CD	Chromatic Dispersion
DAC	Digital to Analog Converter
DCF	Dispersion Compensating Fiber
DLL	Dynamic Link Libraries
DM	Dispersion-Managed
DP-QPSK	Dual Polarization Quadrature Phase Shift Keying
DSP	Digital Signal Processing
EDFA	Erbium Doped Fiber Amplifier
EVM	Error Vector Magnitude
FEC	Forward Error Correction
FWM	Four-Wave Mixing
GN	Gaussian Noise
GVD	Group Velocity Dispersion
IM-DD	Intensity Modulated Direct Detection
I/Q	In phase/Quadrature
ITU	International Telecommunication Union
KB	Knowledge base
K-NN	K-Nearest Neighbor
LO	Local Oscillator
MCI	Multi-Channel Interference

XVIII

MZM	Mach-Zehnder Modulator
NF	Noise Figure
NLI	Non-Linear Interference
NLIN	Non-Linear Interference Noise
NLSE	Non-Linear Schroedinger Equation
OFC	Optical Fiber Communications Conference and Exhibition
OOK	On-Off Keying
OOB	Out of bag error
OPM	Optical Performance Monitoring
OSNR	Optical Signal-to-Noise Ratio
PBC	Polarization Beam Combiners
PBS	Polarization Beam Splitter
PCA	Principal Component Analysis
PDL	Polarization Dependent Loss
PM	Polarization-Multiplexed
PMD	Polarization Mode Dispersion
PM-QPSK	Polarization-multiplexed Quadrature Phase Shift Keying
PDM-QPSK	Polarization-division-multiplexed QPSK
PRBS	Pseudo Random Binary Sequence
PSD	power spectral density
QAM	Quadrature Amplitude Modulation
QoT	Quality of Transmission
QPSK	Quadrature Phase Shift Keying
RBF	Radial Basis Function
RF	Random Forest
ROC	Receiver Operating Characteristic Curve
Rx / Tx	Receiver / Transmitter
SBS	Stimulated Brillouin Scattering
SCI	Self-Channel Interference
SE	Spectral Efficiency

SMF	Single Mode optical Fiber
SNR	Signal-to-Noise Ratio
SPM	Self-Phase Modulation
SRS	Stimulated Raman Scattering
SVM	Support Vector Machine
UT	Uncompensated Transmission
VPI	VPItransmission-Maker™/VPIcomponentMaker
WDM	Wavelength Division Multiplexing
XCI	Cross-Channel Interference
XPM	Cross-Phase Modulation

LISTE DES SYMBOLES ET UNITÉS DE MESURE

c	Vitesse de la lumière en m/s
D	Coefficient de dispersion
dB	Décibel
dBm	Rapport de puissance en décibel par rapport à 1 milliwatt
Gbit/s ou Gb/s	Gigabits par seconde
GHz	Gigahertz
Hz	Hertz
km	Kilomètre
m	Mètre
MHz	Mégahertz
mW	Milliwatt
n	Indice de réfraction
nm	Nanomètre
μm	Micromètre
ps	Picoseconde
THz	Téraherz
W	Watt
α_{lin}	Coefficient d'atténuation en (km^{-1})
β	Coefficient de dispersion en ps^2/km
λ	Longueur d'onde en nm
γ	Coefficient de non linéarité en $1/\text{W}/\text{km}$

INTRODUCTION

L'émergence de services multiples et les exigences en volume de trafic dans les réseaux motivent la conception de réseaux optiques hétérogènes pouvant supporter des débits et des formats de modulation divers, ainsi que différents types de services. La cognition est proposée afin d'assurer le contrôle de ces réseaux. Et les techniques d'apprentissage machine, permettant de baser sa décision sur les expériences passées stockées dans une base de données, sont de plus en plus pressenties pour l'implémentation de cette fonctionnalité dans les réseaux optiques. Plusieurs outils et modèles ont été proposés. Cependant, se basant sur le théorème « *No Free Lunch* » de (Wolpert & Macready, 1997), soutenant qu'aucune solution en apprentissage machine ne peut être déclarée optimale pour un ensemble de données, une étude de trois des techniques d'apprentissage machine appliquée à un ensemble de données synthétiques générées à partir d'un algorithme construit sur MATLAB est présentée dans ce projet.

L'estimation de la QoT à l'aide de modèles analytiques couvrant les dégradations de la couche physique nécessite généralement un temps de calcul élevé. Néanmoins, faire une prédiction de la qualité du signal de nouvelles connexions optiques avant de les implanter dans des réseaux optiques hétérogènes permet d'améliorer les performances du processus à l'aide de la classification de ces connexions optiques en deux classes spécifiques (bonne ou mauvaise QoT).

Les premiers travaux proposés se sont basés sur des systèmes ne dépassant pas un débit de 10 Gbit/s avec un format de modulation en intensité. D'autres solutions couvrant des débits plus élevés et des formats de modulation en amplitude et en phase ont ensuite été développées, cependant le principe des marges est utilisé pour la prise en compte des imperfections non linéaires. La question à la base de ces travaux est la suivante : Pourrait-on utiliser le modèle de bruit gaussien de calcul de la QoT pour développer la cognition dans les réseaux optiques cohérents à haut débit et à formats de modulation avancés ?

Pour pallier à l'absence de données de terrain, une base de données synthétiques de performance a été développée grâce à un algorithme conçu sur MATLAB, qui génère le rapport signal sur bruit optique (*Optical Signal to Noise Ratio*, OSNR), le rapport de densité spectrale de puissance par bit sur bruit (E_b/N_0) et finalement le taux d'erreur binaire (*Bit Error Rate*, BER) de connexions optiques à partir des caractéristiques du signal et du lien.

Les algorithmes des k plus proches voisins K-NN, des forêts aléatoires RF et des machines à vecteurs de support SVM sont les techniques proposées pour la classification des connexions optiques formant la base de données. Et trois métriques de performance sont considérées dans cette étude : la précision, le temps de traitement ainsi que l'évolutivité. Une comparaison de performance de ces trois techniques est proposée et les résultats montrent que le SVM présente un meilleur compromis entre la précision et le temps de traitement, qui sont les métriques de performance les plus importantes de cette étude.

Le but global de ce projet est donc de développer un modèle cognitif d'estimation de la qualité de transmission se basant sur les techniques d'apprentissage machine et tenant compte des effets linéaires et non linéaires de connexions optiques avant leur établissement. Trois classificateurs sont étudiés et comparés suivant les métriques de performance telles que la précision de classification, le temps de traitement et l'évolutivité. On appelle classificateurs les modèles construits par les différentes techniques de classification qui visent à faire correspondre des données d'entrée à une catégorie.

Ce mémoire est divisé en trois parties : La première au chapitre 1 traite de la revue de littérature. Elle permet de présenter les principes des réseaux cognitifs et le projet européen CHRON, précurseur de ce concept. Les principes de base d'apprentissage machine ainsi que d'estimation de la qualité de transmission y sont aussi présentés.

La deuxième partie au chapitre 2 expose la méthodologie adoptée, commençant par une présentation des notions de connexions et de liaisons optiques. Viennent ensuite le développement du modèle de calcul des paramètres de la qualité de transmission.

Le chapitre 3 présente le processus de génération de données synthétiques développées sur MATLAB ainsi que la validation de ces données. Les notions d'apprentissage machine dans les réseaux optiques avec les méthodes de validation des modèles construits par les techniques utilisées sont aussi présentées à la fin de cette section.

La dernière partie au chapitre 4 présente une analyse comparative des résultats obtenus avec les algorithmes de classification. Cette analyse permet de faire le choix de la technique pour l'outil proposé et déterminer si elle est meilleure que d'autres solutions offertes dans le domaine.

Les résultats de cette étude ont fait l'objet de deux publications : l'une dans le cadre de la conférence sur les communications par fibre optique (*Optical Fiber Communications Conference and Exhibition*, OFC) (Aladin & Tremblay, 2018) et l'autre dans le cadre de l'évènement *IEEE Summer Topicals* (Tremblay & Aladin, 2018). La conférence OFC est un évènement mondial qui, depuis plus de quarante ans, rassemble les professionnels travaillant dans le domaine de la communication et des réseaux optiques. Elle fournit des idées sur les principales tendances et avancées technologiques dans l'industrie. De son côté, l'évènement *IEEE Summer Topicals* est une série de conférences consacrées à de nouveaux domaines passionnants des applications, des technologies et de la science photonique, permettant des échanges avec les leaders de la recherche sur les domaines émergents.

CHAPITRE 1

LA COGNITION POUR ESTIMER LA QUALITÉ DE TRANSMISSION DANS LES RÉSEAUX OPTIQUES

Ce chapitre couvre les principes de base des réseaux optiques cognitifs. Les différents concepts d'estimation de la qualité de transmission ainsi que d'apprentissage machine y sont aussi présentés. L'outil E-Tool et les diverses solutions du projet CHRON sont exposés avec leur méthodologie et les résultats obtenus.

1.1 Estimation de la qualité de transmission

La qualité de transmission d'un signal optique peut être estimée selon différentes métriques : l'OSNR, la magnitude du vecteur d'erreur (*Error Vector Magnitude*, EVM), le facteur Q (*Q Factor*) ou le BER. L'OSNR définit le rapport entre la puissance du signal optique et la puissance de bruit optique dans une bande passante donnée. La magnitude du vecteur d'erreur correspond à la norme du vecteur d'erreur qui est la différence entre le vecteur de référence et celui mesuré. Le facteur Q est un facteur lié au rapport signal sur bruit électrique calculé en bout de liaison au niveau du photodétecteur. Le BER définit le rapport des bits avec erreur par rapport au nombre total de bits transmis. L'évaluation de la qualité de transmission se fait à partir de paramètres tels que la topologie du réseau, les caractéristiques du lien et du signal à transmettre de même que des connexions déjà établies dans le réseau de manière à fournir une estimation précise de cette métrique.

(Azodolmolky et al, 2011) ont développé l'outil Q-Tool, qui calcule le facteur Q pour une connexion optique à partir de paramètres tels la topologie du réseau, les caractéristiques physiques et l'état des connexions actives sur le réseau. Cet outil, construit à l'aide de simulations analytiques et numériques, est développé en MATLAB et considère un format de modulation en intensité OOK.

Le Q-Tool tient compte des imperfections, tant statiques que dynamiques, de la couche physique dans les réseaux optiques transparents. Les effets statiques, étant liés à la topologie de réseau, sont pris en compte à l'aide de la méthode (*Split-Step Fourier*, SSF). Ce sont, le bruit lié à l'émission spontanée amplifiée (*Amplified Spontaneous Emission*, ASE), la dispersion chromatique (*Chromatic Dispersion*, CD), la concaténation de filtres et la dispersion de mode de polarisation (*Polarisation Mode Dispersion*, PMD). Les effets dynamiques, quant à eux, dépendent des connexions optiques dans le réseau. Ce sont l'auto-modulation de phase (*Self-Phase Modulation*, SPM), la modulation de phase croisée (*Cross-Phase Modulation*, XPM) et le mélange à quatre ondes (*Four Wave Mixing*, FWM). Dans le modèle analytique utilisé dans le Q-Tool, le bruit ASE de même que les effets FWM sont estimés à l'aide de distribution gaussienne de manière à introduire leur contribution dans la détermination du facteur Q. Les effets XPM et FWM sont considérés comme des effets de bruit aléatoires qui affectent le facteur Q. Un modèle statistique est utilisé pour introduire la pénalité liée à l'effet statique PMD, car la dispersion de mode de polarisation de premier ordre domine dans la configuration de 10 Gbit/s avec un signal codé en non-retour à zéro (*Non-Return-to-Zero*, NRZ), qui est la configuration adoptée dans le développement de l'outil. Le développement du Q-Tool a contribué à fournir un outil qui prend en compte les dégradations qui affectent les performances de la couche physique dans un réseau optique de 10 Gbit/s et de format OOK.

Le projet européen CHRON propose les techniques cognitives pour assurer une optimisation de l'utilisation des ressources du réseau et une réduction de la consommation d'énergie dans le système (Caballero et al, 2014). Les chercheurs ont, entre autres, présenté des algorithmes cognitifs sur l'estimation de la qualité de transmission. Dans ce contexte, ils ont utilisé l'outil Q-Tool, présenté ci-haut, pour générer une base de connaissances leur permettant de construire ces solutions cognitives. Jiménez a proposé un outil cognitif d'estimation de la qualité de transmission pour un réseau à multiplexage de longueur d'onde (*Wavelength Division Multiplexing*, WDM) de 10 Gbit/s, à compensation optique de dispersion et grille fixe (Jiménez et al, 2013).

Les chercheurs du projet CHRON ont ensuite étendu ces travaux en proposant une étude sur un système de transmission WDM à compensation de dispersion, avec 5 canaux de 80 Gbit/s, avec un format de modulation par multiplexage de polarisation et par déplacement de phase en quadrature (*Polarization-Division Multiplexed Quadrature Phase Shift Keying*, PDM-QPSK) (A. Caballero et al, 2012). Ils ont, dans ce cas, pris des mesures de façon à classer chaque instance représentant une connexion optique, décrite à l'aide de différents paramètres tels la puissance de transmission, la longueur de la fibre optique et le nombre de canaux. Les métriques mesurées, permettant de déterminer les classes sont l'OSNR et l'EVM.

Dans un contexte de réseaux optiques à grille flexible et à compensation électronique de dispersion, les chercheurs du projet CHRON ont présenté l'outil TPE-Tool pour des connexions à super canaux, basé sur les modèles analytiques prenant en compte des pénalités liées aux imperfections non linéaires sur la connexion optique. La performance globale est estimée en concaténant les effets de dégradation de chaque segment de lien suivi par la connexion optique ; le rapport signal sur bruit optique est lié aux puissances de bruit d'émission spontanée des amplificateurs et de celui d'interférences non linéaires (*Non-Linear Interference*, NLI) sur la liaison.

Dans les travaux de (Barletta et al, 2017), les chercheurs ont proposé l'outil E-Tool pour la génération de données synthétiques qui leur permettent de tester certaines techniques d'apprentissage automatique dans le but de prédire la qualité de transmission d'une connexion optique avant son établissement dans le réseau optique. La configuration suppose un modèle de bruit additif gaussien (*Additive White Gaussian Noise*, AWGN) applicable à un système de transmission sans compensation de dispersion avec grille flexible. Le rapport signal sur bruit optique accumulé sur le lien est calculé en fonction de la puissance par canal, du gain des amplificateurs et des pertes optiques. Les pénalités liées aux effets non linéaires sont prises en compte par le biais de marge. Le rapport énergie par bit sur la densité spectrale de puissance de bruit E_b/N_0 est calculé à partir du rapport signal sur bruit optique, du débit et du format de modulation. La métrique de qualité de transmission considérée dans cette étude est le BER, et est déterminée comme une fonction de l' E_b/N_0 et du format de modulation.

1.2 Le projet CHRON et l'outil E-Tool

Dans cette section, les travaux effectués sur le processus cognitif basé sur les méthodes d'apprentissage machine permettant de prédire la classe de connexions optiques en utilisant des données passées dans le but d'améliorer la performance du réseau sont explorés.

Dans le projet CHRON, les chercheurs ont développé une architecture de réseau hétérogène qui s'appuie sur la cognition de façon à utiliser une connaissance de l'état actuel du réseau et un processus d'apprentissage afin de répondre aux exigences de qualité de service et de transmission pour les différents types de services et applications.

Un réseau optique hétérogène est un réseau qui utilise simultanément plusieurs technologies de transmission : différents formats de modulation, débits de données, grilles de transmission et type de codage ; ceci dans l'optique de supporter différents types de services avec des exigences spécifiques de qualité de service. On parle d'hétérogénéité en termes de services pris en charge et aussi d'interfaces physiques.

L'acquisition de données de terrain posant un problème dans ce domaine, les chercheurs de ce projet ont eu recours au Q-Tool, développé par (Azodolmolky et al, 2011). Il convient de rappeler que cet outil combine des modèles analytiques et numériques pour évaluer la qualité de transmission. Cependant, il n'est valide que pour les systèmes de transmission à modulation d'intensité et détection directe OOK de débit 10 Gbit/s. Par conséquent, dans l'étude pour démontrer que l'architecture proposée dans le projet CHRON convient aussi aux réseaux de débits plus élevés et formats de modulation en amplitude et en phase et à détection cohérente, les chercheurs ont dû utiliser seulement 153 instances obtenues à partir de mesures expérimentales des paramètres OSNR et EVM réalisées en laboratoire, conduisant à des précisions de classification de l'ordre de 79 à 98.7%.

Par ailleurs, dans les travaux de (Barletta et al, 2017), les chercheurs ont proposé un nouvel algorithme pour la génération des données synthétiques de connexions optiques. Cet

l'algorithme prend en compte les caractéristiques suivantes : le nombre de *spans* de la connexion, la longueur totale de la connexion, la plus grande longueur de lien, le volume de trafic et le format de modulation. Avec cet outil E-Tool, les chercheurs ont obtenu des performances de 99.0 à 99.6% pour des bases d'apprentissage de 1000 et 90,000 instances respectivement. Deux techniques d'apprentissage machine ont été utilisées : les K plus proches voisins K-NN et la forêt aléatoire RF. Et la technique RF a été celle adoptée pour l'outil proposé.

Cette dernière approche est celle qui est utilisée dans le cadre de ce projet. C'est-à-dire, d'abord un algorithme de génération de données synthétiques est proposé. Il est développé sur MATLAB et est basé sur les différents modèles analytiques permettant de déterminer la métrique de qualité de transmission de connexions optiques, BER, à partir des paramètres du lien et du signal transmis. Ensuite, trois techniques d'apprentissage machine sont évaluées à l'aide de ces données pour la classification de ces connexions optiques. Pourrait-on atteindre des niveaux de performance similaires à ceux des différentes solutions présentées dans la section ?

1.3 L'apprentissage machine

La cognition est introduite dans les réseaux optiques grâce aux algorithmes d'apprentissage machine. Ces algorithmes permettent au réseau d'apprendre, d'orienter, de décider et d'agir à partir de données stockées.

Les données collectées ne sont utiles que lorsqu'elles sont analysées pour être transformées en informations, nécessaires aux prédictions. L'hypothèse soutenant le fondement de l'apprentissage machine est que le processus qui sous-tend la génération des données n'est pas complètement aléatoire ; qu'il y a toujours une certaine tendance fournie par les données. Généralement, une approximation permet d'identifier le processus, de détecter des modèles ou régularités. Les prédictions sont, de ce fait, fondées sur ces modèles.

L'apprentissage machine fait partie de l'intelligence artificielle qui est le concept plus large des systèmes intelligents. Se basant sur le traitement de données, l'apprentissage machine suppose que les machines possèdent la capacité d'apprendre et aussi de s'adapter à des changements sans aucune anticipation de solution pour toutes les situations possibles.

L'apprentissage machine consiste à construire des modèles mathématiques en utilisant des expériences passées et la statistique afin de faire des inférences à partir d'un échantillon. Ces modèles peuvent être prédictifs pour faire des prédictions futures, ou descriptifs pour l'acquisition de connaissances à partir de données, ou les deux.

Deux types principaux d'apprentissage existent ; l'un, supervisé, a pour but d'apprendre un lien entre une entrée et une sortie dont les valeurs sont fournies par un superviseur. L'apprentissage non supervisé ne traite que de données d'entrée sans l'aide de superviseur ; le but est de trouver les régularités dans ces données. Un type d'apprentissage intermédiaire existe également, dans lequel l'ensemble de données d'apprentissage contient plus d'informations que l'ensemble de données de test (Shalev-Shwartz & Ben-David, 2014).

L'apprentissage supervisé est celui utilisé dans le projet CHRON où la technique du raisonnement par cas CBR a permis au réseau d'utiliser les observations passées sur celui-ci, c'est-à-dire les configurations ainsi que les paramètres du lien optique, de façon à prédire la QoT de nouvelles connexions optiques (Caballero et al, 2014). Il est aussi utilisé dans le récent projet de (Barletta et al, 2017), de même que dans ces travaux de recherche sur l'intégration de la cognition dans les réseaux optiques.

En apprentissage machine, le théorème « *No Free Lunch* » affirme qu'il n'y a pas de modèle universellement performant (Wolpert & Macready, 1997). Un modèle optimal pour un problème peut ne pas tenir pour un autre problème. De plus, le principe du rasoir d'Occam, selon lequel la solution la plus simple devrait être préférée, guide dans le choix de l'algorithme en tenant compte des différents critères de performance des classificateurs (Shalev-Shwartz et Ben-David, 2014). A la lumière de ces principes, plusieurs techniques

sont évaluées dans les différents travaux proposés sur l'estimation de la qualité de transmission basée sur les techniques d'apprentissage machine. (Caballero et al, 2014) ont comparé les performances des techniques « *Naives Bayes* », « *Decision Tree* », « *Random Forest* », « *J.8 Tree* » à celle du CBR et les chercheurs ont obtenu de meilleurs résultats en termes de précision de classification et de temps de calcul avec cette dernière. Par ailleurs, la précision de classification des connexions optiques de l'algorithme RF a surpassé celle du K-NN dans les travaux de (Barletta et al, 2017).

1.4 Réseaux optiques cognitifs

La complexité des réseaux optiques hétérogènes conduit à des défis dans la gestion des technologies de transmission ainsi que des services requérant différentes qualités de transmission. Cela conduit à l'intégration dans les réseaux optiques de processus pouvant percevoir les conditions du réseau et classer les connexions optiques en se basant sur un apprentissage des caractéristiques du lien et du signal et les utiliser pour prendre des décisions futures (de routage, de reconfiguration, etc.) tout en tenant compte des objectifs du réseau et en minimisant l'intervention humaine.

Les réseaux optiques cognitifs sont construits selon le principe que le réseau puisse utiliser des informations passées sur son état afin de prendre des décisions et de s'adapter. Dans cette section, les recherches liées aux exigences fondamentales et les objectifs des réseaux optiques cognitifs ainsi qu'une évaluation des méthodes d'apprentissage machine utilisées pour rendre possible la cognition dans les réseaux optiques sont abordés.

Un sommaire de différentes méthodes appliquées à des architectures de réseaux optiques, répondant à divers objectifs, décrit les avantages de l'utilisation des algorithmes d'apprentissage machine dans ce domaine :

Récemment, plusieurs algorithmes d'apprentissage machine ont été proposés pour la surveillance de performance optique pour des systèmes de transmission cohérents avec formats de modulation en amplitude et en phase : les réseaux de neurones sont employés pour l'estimation de paramètres de canaux optiques (Khan F. N. et al, 2012) et l'analyse de composantes principales (*Principal Component Analysis*, PCA) pour la classification de formats de modulation (Tan M. C. et al, 2014). La technique PCA vise à détecter la corrélation entre les variables caractéristiques des données d'apprentissage dans le but de les projeter sur un sous-espace de plus petite dimension. La classification de connexions optiques selon le format de modulation est effectuée grâce à une maximisation de la variance des données.

Plusieurs autres techniques ont aussi été utilisées afin de générer des modèles mixtes ainsi que des méthodes statistiques pour la classification de formats de modulation. Les modèles mixtes représentent une technique standard utilisée pour modéliser des données selon une structure hiérarchique, notamment en effectuant des mesures répétées dans le temps. Ce sont les réseaux de neurones, les « *K-Means* » et les méthodes de Bayes, tels que cités dans (Isautier et al, 2014). Jakob Thrane a quant à lui utilisé la régression non linéaire basée sur les réseaux de neurones pour l'estimation du rapport signal sur bruit optique, et la machine à vecteur de support SVM pour la classification de connexions optiques selon quatre formats de modulation en phase et en amplitude à 8, 16 et 64 états : (*Quadrature Phase Shift Keying*, QPSK), (*8-Quadrature Amplitude Modulation*, 8-QAM), (*16-Quadrature Amplitude Modulation*, 16-QAM) et (*64-Quadrature Amplitude Modulation*, 64-QAM) (Thrane et al, 2017).

La méthode CBR est utilisée dans les recherches de (Caballero et al, 2014) pour la classification de connexions optiques en utilisant les métriques de la qualité de transmission (QoT) comme étiquettes. De même, (Barletta et al, 2017) emploient les techniques des K plus proches voisins K-NN et des forêts aléatoires RF dans la classification de connexions optiques avant leur établissement dans le réseau, toujours en se basant sur les paramètres de qualité de transmission.

L'introduction de la cognition dans les réseaux optiques a permis de couvrir divers aspects. Les techniques d'apprentissage machine ont été cruciales dans la classification de connexions optiques selon le format de modulation ou la qualité de transmission. Les recherches sur la classification selon la qualité de transmission ont fourni de très bons résultats en ce qui a trait aux exigences de performance considérées. Néanmoins (Caballero et al, 2014) ont couvert un système de transmission WDM de 80 Gbit/s et un format de modulation à PDM-QPSK avec compensation de dispersion conçu dans un laboratoire afin d'effectuer des mesures d'OSNR pour la construction de la base de données avec seulement 153 instances. Aussi, (Barletta et al, 2017) ont proposé un modèle analytique de calcul de l'OSNR dans lequel les effets non linéaires sont pris en compte sous forme de marge pour un système de transmission avec compensation électronique de dispersion.

1.5 Conclusion

Ce chapitre fait un survol des travaux de recherche sur les réseaux optiques cognitifs, l'apprentissage machine dans les réseaux, le projet des réseaux optiques cognitifs hétérogènes reconfigurables (CHRON) et l'outil E-Tool, présentant la cognition dans les réseaux optiques cohérents à haut débit. Un survol des travaux sur l'estimation de la qualité de transmission dans les liaisons optiques est aussi présenté. Ce survol a permis d'identifier les lacunes des méthodes et outils existants ainsi que des pistes à approfondir pour le développement d'un outil cognitif d'estimation de la qualité de transmission de connexions optiques, tenant compte des effets linéaires et non linéaires dans les liaisons optiques.

CHAPITRE 2

DÉVELOPPEMENT DU MODÈLE DE CALCUL DES PARAMÈTRES DE QUALITÉ DE TRANSMISSION D'UNE LIAISON OPTIQUE

Divers paramètres sont pris en compte pour estimer la qualité de transmission de liaisons optiques. Dans ce chapitre sont décrites les formules analytiques qui permettent de représenter le modèle de calcul de la qualité de transmission d'une liaison optique en tenant compte des imperfections linéaires et non linéaires de la couche physique.

2.1 Notions de connexions optiques et de liaisons optiques

Le besoin de développer des réseaux flexibles à grande capacité et longue distance capables de délivrer de la bande passante sur demande et répondant à diverses requêtes de services sur une infrastructure unique, a conduit au développement de réseaux optiques hétérogènes à multi-débit. Ces derniers offrent de grandes capacités et sont moins sujets aux interférences électromagnétiques (Ramaswami, 2010).

Dans les réseaux optiques à multiplexage de longueurs d'onde WDM, le mécanisme de base de la communication et du transport de trafic entre les nœuds d'un réseau se fait au moyen de la connexion optique. Ces connexions optiques constituent des canaux de communication bout en bout entre les nœuds du réseau qui peuvent être activés et supprimés selon les besoins des utilisateurs du réseau.

Les connexions optiques sont établies de bout en bout d'un nœud source à un nœud de destination sur une longueur d'onde par une liaison optique directe ou via des nœuds intermédiaires. Dans certains cas lors du routage, il peut y avoir conversion ou régénération de longueur d'onde aux nœuds intermédiaires. Différentes connexions optiques dans un réseau WDM peuvent utiliser la même longueur d'onde tant qu'elles ne partagent pas de lien commun. C'est le principe de réutilisation de longueur d'onde dans les réseaux.

La figure 2.1 montre un exemple de connexions optiques dans un réseau WDM à cinq nœuds. La communication entre les nœuds A et C s'effectue sur la liaison optique établie entre ces nœuds à travers la connexion optique sur la longueur d'onde λ_1 . La longueur d'onde λ_2 permet la communication entre les nœuds B et C ou entre les nœuds A et D.




Figure 2.1 Exemple de connexions optiques (λ_1, λ_2) dans un réseau optique WDM à 5 nœuds (A-E)
Tirée de Jiménez et al (2012)

2.1.1 Caractéristiques de la transmission optique

L'introduction des technologies cohérentes dans les systèmes de transmission WDM implique la possibilité de compenser électroniquement les effets de dispersion (CD et PMD) grâce au module de traitement de signal (*Digital Signal Processing*, DSP) au récepteur. La compensation électronique change certaines caractéristiques de la propagation du signal et de la génération de nonlinéarité dans la fibre optique.

Les technologies à modulation d'intensité et détection directe (Intensity Modulation Direct Detection, IM-DD)

Les systèmes de communications optiques IM-DD supposent la modulation de l'intensité de la lumière produite par un laser à semi-conducteur, le transport du signal optique à travers une fibre optique et la détection directe du signal optique par une photodiode à la sortie de la fibre optique. Le principe consiste à faire varier le courant du laser à semi-conducteur. C'est une solution fiable et rentable qui peut se révéler très pratique pour certaines applications. La figure 2.2 montre un exemple de système de communication optique à modulation d'intensité et détection directe.




Figure 2.2 Diagramme simplifié d'un système de communication optique à modulation d'intensité et détection directe
Tirée de Hranilovic et al (2003)

Les technologies cohérentes

La technologie de modulation d'intensité avec détection directe est très sensible aux imperfections de la fibre optique lorsque le débit dépasse 10 Gbit/s. La modulation d'amplitude et/ou de phase, soutenue par la technologie cohérente, a été proposée pour répondre au besoin de débits et de distances de transmission élevés. Les technologies cohérentes supposent la modulation d'amplitude et/ou de phase, un multiplexage par polarisation, un oscillateur local (*Local Oscillator*, LO) pour la détection cohérente au

récepteur, des convertisseurs analogiques-numériques (*Analog to Digital Converter*, ADC) à haute vitesse ainsi qu'un module de traitement de signal DSP au récepteur.

La modulation d'amplitude et/ou de phase et multiplexé en polarisation permet d'augmenter le nombre de bits par symbole et la sensibilité aux imperfections de la fibre optique se rapporte au débit de symboles plutôt qu'au débit binaire. La figure 2.3 décrit le circuit d'un transmetteur utilisant un modulateur Mach-Zehnder (*Mach-Zehnder Modulator*, MZM) pour coder les données sur la porteuse optique.




Figure 2.3 Circuit d'un transmetteur PSK Adaptée de Infinera (2016)

La lumière du laser pénètre au point A du modulateur MZM et est divisée en deux afin de passer dans les deux bras du modulateur. Le signal est appliqué au point B, changeant l'indice de réfraction, donc la vitesse effective de la lumière. Des changements de phase sont donc codés sur la lumière recombinaison au point C. La constellation de phase résultant est illustrée dans la figure. Les symboles de phase sont interprétés par rapport à leur position sur cette constellation. C'est le principe de la modulation par déplacement de phase binaire (*Binary Phase Shift Keying*, BPSK).

Une fibre optique monomode est capable de supporter deux polarisations orthogonales. La polarisation multiplexée consiste donc à émettre les signaux sur une porteuse unique en utilisant les deux états de polarisations orthogonales. Dans ce cas le symbole devient la combinaison des états amplitude/phase et des états de polarisation. Ce principe permet de

doubler l'efficacité spectrale d'une technique de modulation donnée. La figure 2.4 décrit un transmetteur (*Polarization-Multiplexed Quadrature Phase Shift Keying*, PM-QPSK) avec deux états de polarisation X et Y et quatre symboles différents.




Figure 2.4 Circuit d'un transmetteur PM-QPSK,
Adaptée de Infinera (2016)

Dans les récepteurs à détection directe, le signal transmis est détecté par une photodiode dont la sortie est proportionnelle au carré du champ électrique du signal d'entrée. Dans ce cas, la sensibilité du récepteur ne dépend ni de la phase ni de la polarisation de la porteuse du signal d'entrée.

Les récepteurs cohérents sont munis d'un oscillateur local qui permet l'extraction de l'information de la phase du signal. Les informations complètes des composantes de phase et d'amplitude du champ électrique ainsi que les états de polarisation du signal peuvent être restitués sur les porteuses optiques (Kazuro Kikuchi, 2016). Les récepteurs cohérents sont donc capables de traiter des formats de modulation à plusieurs niveaux. De plus ils disposent de fonctions de compensation de la dispersion chromatique et de dispersion par mode de polarisation. La figure 2.5 ci-dessous décrit l'exemple d'un récepteur cohérent avec un module de traitement de signal numérique. Les différentes composantes sont (*Polarization Beam Splitter*, PBS) qui divise le signal optique entrant en deux signaux de polarisations

orthogonales. Chacun de ces signaux optiques est ensuite constitué l'un de composant polarisé en X et l'autre du composant polarisé en Y. Chaque composant passe dans un coupleur optique deux par deux avec une fonction de retard de phase de 90 degrés implémentée sur un bras du coupleur. Cet élément porte le nom de circuit hybride optique à 90 degrés et permet l'extraction des composantes de modulation et de phase du signal (I et Q) résultant des interférences générées par l'oscillateur local. Des photodétecteurs permettent ensuite une conversion optoélectronique des signaux de phase. Des convertisseurs ADC se chargent de numériser les signaux électriques en bande de base pour ensuite acheminer le signal dans le module de traitement de signal numérique DSP pour la récupération du signal transmis grâce à la synchronisation de la phase de la porteuse.




Figure 2.5 Récepteur cohérent avec DSP
Adaptée de Xiaogang Yi et al (2012)

Les grilles flexibles dans les réseaux WDM

Dans les systèmes optiques à grille fixe, il existe une fréquence centrale fixe avec un espacement de canal fixe de 50 ou de 100 GHz. Dans ce contexte il n'y a pas d'ajustement de bande passante. Et dans le cas de transmission de signaux de débits multiples sur le réseau optique, la bande passante spectrale maximale requise détermine l'espacement de canal fixe, ce qui peut causer un gaspillage de spectres. Afin d'améliorer l'utilisation du spectre, la

technologie de grille flexible a été proposée. Cette technologie permet de fournir un espacement des canaux de largeur allant de 37.5 à 400 GHz. Le spectre est divisé en tranches plus petites, par exemple de 12.5 GHz. Ainsi le signal peut occuper plusieurs tranches du spectre et un ajustement flexible de la bande passante permet d'améliorer l'utilisation du spectre sur le réseau.

Cette technologie présente divers avantages tels la sélection aléatoire de tranches de spectre de manière à permettre l'utilisation sur différentes bandes passantes, l'ajustement flexible de la fréquence centrale des longueurs d'onde et l'amélioration de l'utilisation de la bande passante grâce à la réduction de l'espacement entre les bandes dans un système de transmission multi-débits tout en respectant les exigences de capacité élevée.

Dans ce projet, l'espacement de canal considéré est fixé à 50 GHz. Dans la bande C, cela correspond à un nombre de canaux allant jusqu'à 80. Le nombre de canaux est fixé à 9 canaux dans les calculs de puissance de bruit d'interférence.

Les liens typiques de liaisons métro à internationales de longueurs variant entre 80 et 7500 km, avec des *spans* de longueurs typiques variant de 80 à 150 km sont considérés. Le signal est amplifié après chaque *span*, à l'aide d'amplificateurs à fibre dopée à l'erbium (*Erbium Doped Fiber Amplifier*, EDFA) dans la fenêtre de faible perte de la fibre optique (bande C 1530 - 1565 nm).

L'amplificateur EDFA est essentiellement de la fibre optique de longueur inférieure ou égale à quelques dizaines de mètres, dopée avec de l'élément erbium. Une source de pompage change l'état fondamental des atomes d'erbium à un état excité à un niveau d'énergie plus élevé. Un photon de signal entrant déclenche le retour de ces atomes à leur état fondamental. Dans ce processus, chaque atome émet un photon. Ainsi les photons du signal déclenchent l'émission de photons supplémentaires, ce qui entraîne l'amplification optique. L'amplification optique est caractérisée par deux paramètres : le gain (G) et le facteur de

bruit (*Noise Figure*, NF) définie comme étant une mesure de la dégradation du rapport du signal sur bruit entre l'entrée et la sortie de l'amplificateur.

Les différents paramètres d'un système de transmission qui entrent dans le cadre de cette étude sont le taux de symboles, la fréquence des canaux, le nombre de canaux, la puissance moyenne de transmission, le format de modulation et le facteur de bruit des amplificateurs.

Le support qui assure le transport des signaux optiques dans les réseaux optiques est la fibre optique. Cette fibre optique est essentiellement un guide d'ondes qui transporte les signaux optiques sous la forme d'ondes lumineuses modulées. Dans la section suivante sont abordées les caractéristiques des fibres optiques, qui sont des paramètres importants dans le cadre de ce projet.

2.2 Effets linéaires dans une fibre optique

A l'ère des réseaux Internet, la fibre optique est largement utilisée dans les réseaux d'accès, métropolitains, nationaux et internationaux car elle possède une bande passante très large qui permet de transporter d'énormes quantités de trafic sur des distances très grandes. En plus de cette propriété, elle présente l'avantage de transmettre à faible perte des signaux sur de longues distances (jusqu'à 10,000 km) à des débits élevés (100 Gbit/s et plus par longueur d'onde ou canal) avant régénération.

Cependant, la fibre optique possède certaines caractéristiques qui affectent la qualité de transmission du signal optique dans les réseaux et donc requièrent notre attention. Les effets de propagation peuvent être classés en caractéristiques linéaires et non linéaires. Les effets linéaires incluent l'atténuation, la dispersion chromatique CD, la dispersion de mode de polarisation PMD et les pertes dépendantes en polarisation PDL. Alors que les effets non linéaires régis par des facteurs tels que le débit binaire, l'espacement entre les canaux et le niveau de puissance, incluent la diffusion Brillouin stimulée (*Stimulated Brillouin Scattering*,

SBS) et la diffusion Raman stimulée (*Stimulated Raman Scattering*, SRS) qui sont dues aux interactions des ondes lumineuses avec les atomes de silice. D'autres effets tels que l'auto-modulation de phase SPM, la modulation de phase croisée XPM et le mélange à quatre ondes FWM se produisent en raison de la dépendance de l'indice de réfraction sur l'intensité qui est proportionnelle au carré de l'amplitude du champ électrique du signal.

L'atténuation dans la fibre optique

De nombreuses caractéristiques entrent dans le choix de la fibre optique pour le déploiement de réseaux optiques. La fibre monomode est utilisée dans tous les réseaux (d'accès, métro à inter-continent). La fibre multimode est soumise à la dispersion intermodale qui limite fortement le débit du signal transmis ainsi que la distance de transmission.

La caractéristique la plus importante de la fibre optique est l'atténuation. Ce paramètre décrit la diminution de la puissance du signal en fonction de la distance. Le coefficient d'atténuation α d'une fibre optique est exprimé en dB/km et varie avec la longueur d'onde λ . Dans ces travaux, sa valeur est fixée à 0.22 dB/km dans la bande C ($1530 \leq \lambda \leq 1560$ nm) pour la transmission WDM.

La dispersion dans la fibre optique

La dispersion est l'étalement temporel de l'impulsion du signal optique qui se propage dans la fibre optique. Cet étalement peut conduire à des interférences inter symboles, contribuant à limiter le débit dans le canal de transmission de la fibre optique. Plusieurs types de dispersion existent dans la fibre optique. La dispersion intermodale est caractéristique de la fibre multimode, car elle survient lorsque les divers modes de propagation du signal se propagent à des vitesses différentes dans la fibre optique. Dans la fibre monomode, ce sont la dispersion

intramodale ou dispersion chromatique et la dispersion des modes de polarisation qui causent l'étalement temporel des impulsions optiques.

La dispersion chromatique CD provient du fait que la vitesse de propagation dépend de la longueur d'onde du signal optique. Cette variation de vitesse en fonction de la longueur d'onde peut dépendre du matériau, des indices et de la dimension du cœur et de la gaine de la fibre optique, et aussi de la variation des indices de réfraction en rapport aux longueurs d'onde dans la fibre optique. La dispersion chromatique porte aussi le nom de dispersion de vitesse de groupe (*Group Velocity Dispersion*, GVD) et le coefficient de dispersion D , qui dépend de λ , est une spécification de la fibre optique. Ce paramètre s'exprime en ps/nm.km et est lié à la constante de propagation (β_2 en ps²/km) et à la vitesse de la lumière c par la relation :

$$D = -\frac{2\pi c}{\lambda^2} \times \beta_2 \quad (2.1)$$

La valeur de D pour les fibres monomodes ITU-T G.652 varie entre 15 et 19 ps/nm.km environ dans la bande C utilisée pour la transmission WDM.

La dispersion de mode de polarisation PMD provient du fait que les deux modes de polarisations orthogonales de la fibre monomode s'y propagent à des vitesses différentes. Les effets de la PMD sont considérés faibles et ne sont donc pas pris en compte dans les calculs car il est pris pour acquis que ceux-ci peuvent être compensés au récepteur cohérent. Le coefficient de PMD en ps/ $\sqrt{\text{km}}$ est une spécification de la fibre optique. Pour les fibres optiques récentes, la valeur se situe autour de 0.05 ps/ $\sqrt{\text{km}}$.

Les pertes dépendantes en polarisation PDL se traduisent par une variation de pertes causée par un changement des états de polarisation dans la fibre optique. Les systèmes cohérents permettent d'améliorer la tolérance à ces pertes.

2.3 Effets non linéaires dans une fibre optique

Le coefficient de nonlinéarité

Dans les liaisons optiques amplifiées, les effets non linéaires dépendent de la distance d'interaction. Les effets non linéaires augmentent avec la longueur du lien alors que la puissance par canal diminue avec la distance.

La longueur effective L_{eff} est un paramètre utile pour modéliser les effets non linéaires. Elle est définie comme la distance effective à laquelle la puissance par canal est jugée constante. Cette longueur est donnée par la formule tirée de (Ramaswami, 2010) :

$$L_{eff} = \frac{1 - e^{-\alpha L}}{\alpha} \times \frac{L_A}{L} \quad (2.2)$$

avec L_A : Longueur totale du lien, L : Longueur du *span* et α : Valeur linéaire du coefficient d'atténuation en km^{-1}

Voici un exemple de calcul de la longueur effective d'une fibre optique pour un lien de 800 km, avec des *spans* de 80 km et un coefficient d'atténuation α de 0.2 dB/km :

$$\alpha_{lin} = \frac{\alpha_{dB}}{10 \log e}$$

$$\alpha_{lin} = \frac{0.2}{10 \times 0.4343} = 0.046 \text{ km}^{-1}$$

$$L_{eff} = \frac{1 - e^{-0.046 \times 80}}{0.046} \times \frac{800}{80}$$

La longueur effective de ce lien est de 211.9 km.

Lors de la conception et la planification de liaisons optiques WDM à haute capacité déployées sur de grandes distances, il est essentiel de considérer les effets de Kerr. Ce sont des effets non linéaires qui proviennent des variations de l'indice de réfraction de la silice en

fonction de l'intensité du signal optique. L'auto-modulation de phase SPM, la modulation de phase croisée XPM et le mélange à quatre ondes FWM sont les principaux effets non linéaires considérés et le coefficient de non linéarité γ de la fibre optique, pilote la génération de ces effets. Il est exprimé selon la relation :

$$\gamma = \frac{n_2}{A_{eff}} * \frac{2\pi}{\lambda} \quad (2.3)$$

où A_{eff} est l'aire effective et n_2 l'indice de réfraction non linéaire de la fibre optique, deux paramètres qui font partie des spécifications de la fibre optique. La valeur typique du paramètre γ est de $1.3 \text{ W}^{-1}\text{km}^{-1}$.

2.3.1 Les effets non linéaires dans les liaisons optiques à compensation électronique de dispersion

Dans la plupart des modèles de transmission où la dispersion n'est pas compensée dans la ligne, la nonlinéarité est supposée relativement faible par rapport au signal utile. Et l'interférence non linéaire (NLI) est considérée comme un bruit gaussien additif (Pierluigi Poggiolini, 2012).

Trois principaux effets non linéaires contribuent au NLI et sont aussi considérés comme des bruits gaussiens qui s'ajoutent au signal. Ce sont l'auto-interférence de canal (*Self-Channel Interference*, SCI), l'interférence de canal croisée (*Cross-Channel Interference*, XCI) et l'interférence multi canal (*Multi-Channel Interference*, MCI).

L'auto-interférence de canal SCI est l'effet non linéaire causée par un canal sur lui-même. Ce phénomène est expliqué par (Pierluigi Poggiolini, 2012) où trois composantes de fréquence appartiennent toutes à un même canal central et les battements de ces trois composantes spectrales du signal s'ajoutent à la fréquence centrale de ce même canal. Il est décrit à la figure 2.6 ci-dessous.




Figure 2.6 Auto-interférence de canal
Adaptée de Pierluigi Poggiolini (2012)

L'interférence de canal croisée XCI implique une interaction entre le canal central et un seul autre canal. Cette contribution porte encore le nom « d'interférence entre canaux ». La figure 2.7 illustre ce phénomène.




Figure 2.7 Interférence de canal croisée
Adaptée de Pierluigi Poggiolini (2012)

L'interférence multi-canal MCI fait intervenir au moins deux autres canaux en plus du canal central. Cette contribution implique deux ou plusieurs canaux, parfois sans inclure le canal central.




Figure 2.8 Interférence multi-canal
Adaptée de Pierluigi Poggiolini (2012)

Dans les systèmes IM-DD à compensation optique de dispersion, les deux premières contributions non linéaires sont connues sous les noms d'auto-modulation de phase SPM, et modulation de phase croisée XPM. Malgré les ressemblances, il n'y a pas de correspondance avec ces dernières, bien structurées dans le système IM-DD à compensation optique de dispersion et les interférences non linéaires gaussiennes NLI dans un système cohérent à compensation électronique de dispersion.

Comme expliqué dans la section 2.2, d'autres effets non linéaires tels que la diffusion stimulée de Brillouin SBS, la diffusion stimulée de Raman SRS et le mélange à quatre ondes FWM affectent le signal transmis.

Le SBS produit un retour vers la source, appelé onde de Stokes, qui est l'onde non désirée générée par le processus de diffusion du signal optique par les atomes de silice de la fibre optique. Ainsi il affecte le signal transmis et génère un signal potentiellement fort vers l'émetteur. L'effet a une bande passante très étroite variant de 20 à 100 MHz à 1550 nm selon les caractéristiques de la fibre optique. Il ne provoque pas d'interaction entre différentes longueurs d'onde puisque l'espacement entre les canaux est beaucoup plus grand (50 ou 100 GHz) que 100 MHz.

Le SRS quant à lui est un effet de large bande qui cause un transfert de puissance des canaux de longueur d'onde inférieure vers les canaux de longueur d'onde supérieure. L'énergie d'un

photon est inversement proportionnelle à la longueur d'onde. Donc le transfert d'énergie d'un signal de longueur d'onde inférieure à un signal de longueur d'onde supérieure correspond à l'émission de photons d'énergie inférieure provoquée par des photons d'énergie plus élevée. Le couplage de canaux se fait dans la direction de propagation. La puissance de seuil SRS étant très élevée dans les systèmes avec un petit nombre de canaux, le SRS n'est pas un problème. Cependant, il devient critique quand le nombre de longueurs d'onde est élevé.

Le mélange à quatre ondes FWM est un effet de Kerr qui se produit lorsque l'interaction de trois longueurs d'onde différentes conduit à une quatrième longueur d'onde qui peut chevaucher les autres longueurs d'onde dans la fibre optique. Cela produit une interférence entre le signal et les données transmises sur cette longueur d'onde.

Etant donné que la dispersion chromatique provoque une propagation des signaux lumineux de différentes longueurs d'onde à différentes vitesses dans la fibre, elle conduit à moins de chevauchement entre ces signaux, ce qui réduit l'effet de nonlinéarité FWM.

Dans un contexte de transmission à compensation électronique de dispersion, la modélisation des interférences non linéaires NLI adoptée par (Pierluigi Poggiolini, 2012) prend en compte les contributions des interférences SCI, XCI et MCI. Les effets SPM et XPM ne sont pas applicables à ces systèmes de transmission vue que les contributions des interférences se manifestent différemment de ces effets traditionnels (Pierluigi Poggiolini, 2012). Les effets des diffusions stimulées de Brillouin et de Raman sont considérés négligeables car les valeurs de la puissance de transmission par canal utilisées dans le projet sont très petites (Le Nguyen Binh, 2015). Les effets du mélange à quatre ondes sont quant à eux pris en compte dans le développement du modèle de bruit gaussien (Poggiolini et al, 2014).

2.4 Qualité de transmission optique et le modèle de bruit gaussien additif

Les systèmes de transmission sans compensation de dispersion (*Uncompensated Transmission*, UT) font référence aux systèmes cohérents équipés de module de traitement numérique du signal DSP qui permet une compensation électronique de la dispersion chromatique CD de la fibre optique. Ces systèmes procurent, selon (Poggiolini et al, 2012), un cadre propice aux modèles de perturbation de propagation non linéaire des fibres, où ces modèles peuvent fournir des performances de systèmes précises.

La propagation non linéaire dans les fibres optiques est un élément important de la conception des systèmes de communication par fibre optique. Vu la complexité des cas de simulations de réseaux optiques à multiplexage de longueurs d'onde, les modèles analytiques semblent indispensables pour la représentation de ce phénomène dans les études de performance dans ces systèmes.

(Poggiolini et al, 2014) ont publié plusieurs travaux sur les systèmes optiques dans lesquels ils modélisent le bruit d'interférence non linéaire NLIN comme un bruit gaussien additif. La précision de ce modèle de bruit gaussien a été validée dans de nombreuses études selon (Poggiolini et al, 2014). Ce modèle de bruit gaussien GN dans un contexte de liens de transmission sans compensation optique de dispersion permet de déterminer le rapport signal sur bruit optique à partir de la puissance de transmission, des gains et des pertes sur le lien. Et les différentes formules utilisées dans ce projet sont présentées dans cette section.

2.4.1 Formule analytique de la qualité de transmission

L'algorithme de génération de données synthétiques se base sur les modèles analytiques permettant le calcul de l'OSNR à partir de la puissance de transmission, de celle de l'émission spontanée amplifiée et de celle du bruit d'interférence non linéaire. Et comme spécifié ci-haut, le modèle de perturbation de bruit gaussien GN qui est un modèle simple mais suffisamment fiable pour la prédiction de performance de multiples scénarios dans un contexte d'analyse et de conception de systèmes (Poggiolini et al, 2013) a été utilisé.

Cette formule de calcul de l'OSNR découle des trois hypothèses suivantes :

- les effets non linéaires sont considérés faibles par rapport au signal transmis. Ainsi les techniques de perturbation permettent de résoudre analytiquement l'équation non linéaire de Schroedinger (*Non Linear Schroedinger Equation*, NLSE) ;
- le signal se propage sur un lien sans compensation de dispersion et se comporte comme une distribution gaussienne ;
- la puissance de bruit des interférences non linéaires est considérée comme un bruit gaussien additif tout comme le bruit d'émission spontanée amplifiée.

Et elle s'écrit :

$$OSNR = \frac{P_{TX}}{P_{ASE} + P_{NLI}} \quad (2.4)$$

où P_{TX} est la puissance de transmission par canal, P_{ASE} est la puissance de l'émission spontanée amplifiée et P_{NLI} est la puissance de bruit d'interférence non linéaire.

Le produit de la densité spectrale de puissance de l'émission spontanée amplifiée et de la bande passante de bruit permet d'obtenir la P_{ASE} :

$$P_{ASE} = N_S * F * (A_S - 1) * h * \mu * B_N \quad (2.5)$$

où :

N_S est le nombre de *spans* du lien optique. Ce nombre dépend de la longueur totale du lien et de la longueur de chaque *span*.

F est la figure de mérite des amplificateurs et est fixée comme dans les travaux de (Barletta et al, 2017)

A_S est le gain des amplificateurs. Il est le produit du coefficient d'atténuation en dB/km et de la longueur de *span*.

h est la constante de Planck et μ est la fréquence du canal central qui vaut 193.1 THz.

B_N est la bande passante de bruit.

La puissance de bruit d'interférence non linéaire est calculée à partir du produit de la densité spectrale de puissance NLI et de la bande passante de bruit:

$$P_{NLI} = 8/27 * NS * \gamma * L_{eff} * P_{TX}^3 * \frac{\log(\pi^2 * \beta * L_{eff} * N_{ch}^2 * R_S^2)}{\pi * \beta * R_S^3} * B_N \quad (2.6)$$

avec :

L_{eff} , la longueur effective de *span*, qui s'obtient par la formule (2.2) de la section 2.3. Sa valeur varie avec la longueur de *span*.

R_S est le taux de symboles en Gbaud.

N_{ch} est le nombre de canaux.

β est le coefficient de dispersion en ps²/km.

γ est le coefficient de nonlinéarité de la fibre en W⁻¹km⁻¹.

Le taux d'erreur binaire BER et le rapport de l'énergie par bit et de la densité spectrale de bruit Eb/N0

Les différents formats de modulation avancés BPSK, QPSK ou QAM présentent des courbes différentes de taux d'erreur binaire BER par rapport à Eb/N0. Pour les quatre formats étudiés, il est possible d'établir la relation :

$$BER = a * \operatorname{erfc}\left(\sqrt{\frac{Eb/N0}{d}}\right) \quad (2.7)$$

avec : $a = 1/2$ et $d = \log_2(M)$ pour les formats de modulation par décalage de phase PSK. Pour la modulation 16-QAM, $a = 3/8$ et $d = 10$ et dans le cas de la modulation 64-QAM, la valeur du taux d'erreur binaire est directement tirée de la table de valeurs du BER en fonction du ratio Eb/N0 générées dans le cadre de (Barletta et al, 2017).

Le rapport de l'énergie par bit, E_b et de la densité spectrale de bruit, N_0 est la mesure de base de la force du signal à l'entrée du récepteur d'un lien. C'est un paramètre très important dans les systèmes de transmission. Il est lié au rapport signal sur bruit optique total du lien par l'équation 2.8 :

$$Eb/N0 = OSNR - 10 * \log_{10}(\log_2(M)) - 10 * \log_{10}(Datarate/2 * \log_2(M) / B_{ref}) \quad (2.8)$$

où M représente le nombre d'états par symbole. $Datarate$ est le débit et B_{ref} est la bande passante de référence à 0.1 nm.

2.5 Conclusion

Dans ce chapitre, le développement du modèle de calcul de la qualité de transmission de la liaison optique est décrit. Les caractéristiques des connexions et des liaisons optiques sont d'abord présentées. Ensuite le choix du modèle AWGN de calcul analytique de l'OSNR prenant en compte les différentes imperfections linéaires et non linéaires de la fibre optique est présenté (Poggiolini et al, 2014). Aussi, la méthode de calcul du rapport de l'énergie par bit et de la densité spectrale de bruit telle que proposée par (Barletta et al, 2017), permettant de prendre en compte le rapport signal sur bruit optique final du lien, le format de modulation ainsi que le débit de l'instance de connexion optique y est expliquée pour la détermination du BER.

CHAPITRE 3

ESTIMATION DE LA QOT DE CONNEXIONS OPTIQUES DANS LES RÉSEAUX WDM COHÉRENTS À COMPENSATION ÉLECTRONIQUE DE DISPERSION À L'AIDE DE TECHNIQUES D'APPRENTISSAGE MACHINE

La prise en charge de différents débits de ligne, formats de modulation et exigences de qualité de service dans des réseaux optiques hétérogènes rend très difficile l'évaluation de la QoT des connexions optiques. La cognition a été proposée pour prédire la QoT de connexions optiques non-établis en implémentant dans le système de contrôle de réseau un processus de prise de décision basé sur des techniques d'apprentissage machine pour apprendre des scénarios passés stockés dans une base de connaissances.

Dans ce chapitre, un modèle d'estimation de la QoT est proposé, dans lequel les imperfections non linéaires sont intégrées dans la formule analytique de l'OSNR basée sur le modèle de bruit gaussien décrit dans (Poggiolini, 2012). Le BER est ensuite estimé en fonction du rapport de l'énergie par bit sur la densité spectrale de puissance de bruit E_b/N_0 , le débit et le format de modulation. L'algorithme développé à partir de ces modèles a permis de générer la base de données synthétiques qui sont ensuite validées afin de s'assurer de la qualité de ces données avant l'application des trois techniques d'apprentissage machine, aussi présentées dans ce chapitre.

Le processus global de l'étude est décrit dans la figure 3.1 ci-dessous, incluant les étapes de la génération des données ainsi que leur validation :




Figure 3.1 Schéma global de l'étude
Tirée de Aladin & Tremblay (2018)

3.1 Génération de données synthétiques de BER sur MATLAB

Les réseaux optiques hétérogènes fournissent une multitude de services qui requièrent diverses qualités de service et de transmission. L'intégration de techniques cognitives dans ces environnements vise à permettre à ceux-ci d'observer, d'agir, d'apprendre et d'optimiser ses performances. Ce qui contribue à répondre aux défis de gestion et de complexité de ces réseaux.

Un réseau optique cognitif est capable de prendre des décisions futures en se basant sur les expériences passées ainsi que l'état actuel du réseau, tout en tenant compte des objectifs de bout en bout (Thomas, DaSilva et MacKenzie, 2005). Ces expériences passées peuvent contenir des informations sur l'état du réseau, recueillies à l'aide de mécanisme de surveillance de performance de réseau (*Optical Performance Monitoring*, OPM). Le processus classique implique des appareils tels les oscilloscopes ou les analyseurs de spectre optique pour la surveillance du signal. Ces informations peuvent aussi être récupérées à l'aide de l'échantillonnage numérique et du traitement de signal combinés à la détection cohérente (Caballero, Borkowski, Zibar et Monroy, 2013). Dans une étude, (Jiménez et al, 2013), ont utilisé le Q-Tool, un outil d'estimation de la qualité de transmission préalablement

développé par (Azodolmolky et al, 2011), afin de générer les données de leur base de connaissances KB. Cependant cet estimateur ne couvre que les connexions optiques de 10 Gbit/s avec un format de modulation en intensité OOK. Dans (Caballero et al, 2012), des mesures expérimentales ont été prises pour construire la base de connaissances couvrant un système de transmission à multiplexage de longueurs d'onde WDM de 80 Gbit/s et un format de modulation à multiplexage de polarisation PDM et déplacement de phase en quadrature QPSK. Dans le cadre de ce projet, un algorithme a été développé sur MATLAB pour la génération de données synthétiques, à l'instar de la méthode utilisée par (Barletta et al, 2017) pour le développement de l'outil d'estimation de la qualité de transmission de connexions optiques avant leur établissement.

L'algorithme consiste à utiliser les différentes formules analytiques présentées dans le chapitre précédent afin de déterminer les paramètres de qualité de transmission. L'OSNR est déterminé à partir de la puissance de transmission par canal qui varie entre -10 et 5 dBm pour 16 instances différentes. La longueur totale de lien varie de 80 à 7500 km avec quatre longueurs de *span* de 80, 100, 120 et 150 km pour des nombres de *spans* N_s entiers. La figure de mérite des amplificateurs est fixée à 5 dB comme dans (Barletta et al, 2017). La fréquence du canal central μ est de 193.1 THz dans la bande C. La bande passante de bruit est fixée à 32 GHz en référence au taux de symbole R_s qui a pour valeur 32 Gbaud. Ce taux de symbole a été choisi en référence à un des scénarii de test dans (Poggiolini et al, 2014), de même que le nombre de canaux qui est égal à 9. La constante de Planck est égale à $6.626 \times 10^{-34} \text{ m}^2\text{kg/s}$.

Le coefficient de dispersion β est déterminé à partir du coefficient de dispersion D de 17 ps/nm.km et de la longueur d'onde λ de 1550 nm avec la vitesse de la lumière c de 3×10^8 m/s. La valeur obtenue est de -21 ps²/km. Le coefficient de nonlinéarité γ a une valeur typique de $1.3 \text{ W}^{-1}\text{km}^{-1}$.

Quatre formats de modulation sont considérés dans le cadre du projet : BPSK, QPSK, 16-QAM et 64-QAM. Ils sont représentés par le paramètre M qui est le nombre d'états par symbole avec des valeurs respectives de 2, 4, 16 et 64 correspondant à ces formats.

Deux valeurs théoriques de débits sont prises en compte 50 et 100 Gbit/s et la bande passante de référence B_{ref} des canaux à 0.1 nm est de 12.5 GHz.

Les données de BER générées sont des instances composées chacune des différents paramètres de la fibre optique et de la transmission et qui permettent de calculer le rapport signal sur bruit optique OSNR, puis de déterminer le rapport de l'énergie par bit et de la densité spectrale de bruit E_b/N_0 , pour ensuite calculer le taux d'erreur binaire BER. Ces paramètres forment donc le vecteur de caractéristiques pour les algorithmes d'apprentissage machine. Et le BER calculé représente l'étiquette de chacune des observations de la base de données.

Le taux d'erreur binaire seuil B_{th} est de 4×10^{-3} pour une correction d'erreur à l'aide de la technique FEC. Cette valeur est choisie selon la recommandation UIT-T G.975.1.

La base de données générée compte au total 25,600 observations de BER pour différentes connexions optiques avec les étiquettes correspondantes : 6,160 instances avec une bonne qualité de transmission ($BER < B_{th}$) et 19,440 avec une pauvre qualité de transmission ($BER > B_{th}$).

Mise à l'échelle

La fonction z-score de MATLAB *zscore*, est utilisée pour une mise à l'échelle des données de la base de connaissances afin d'éliminer l'instabilité due à la disparité entre les plages de valeurs de ces données. Cette fonction retourne une matrice de même taille que celle de la

matrice des données caractéristiques et opère de manière à centrer les valeurs de cette dernière pour avoir une moyenne de 0 et un écart-type de 1.

3.2 Validation des données synthétiques

Une validation des données de BER est effectuée grâce à l'outil (*Non-Linear Interference Noise*, NLIN Wizard) développé par (Dar et al, 2013). De plus, un échantillon de valeurs d'OSNR est comparé à des mesures d'OSNR effectuées sur une liaison compensée WDM DP-QPSK à 112 Gbits/s. Cette étape de validation permet de s'assurer de la qualité des données de la base de connaissances générées à partir de l'algorithme sur MATLAB.

3.2.1 Validation d'une liaison WDM 112 Gbit/s à 4 canaux avec l'outil web *NLIN Wizard*

L'outil *NLIN Wizard* a été développé par (Dar et al, 2013). Il est décrit ci-dessous, avec les différents paramètres d'entrée et les options offertes pour une estimation précise des puissances de bruits non linéaires et de l'émission spontanée amplifiée, ainsi que du rapport signal sur bruit reçu. Il est très utile pour la validation des calculs de ces métriques. Cependant la saisie de chaque connexion se fait manuellement et l'outil met un temps de l'ordre de la dizaine de secondes pour retourner les valeurs de P_{NLI} , P_{ASE} et OSNR. Dans le cas du lien WDM analysé, un OSNR de 15.08 dB est obtenu. Cette valeur est très proche de celle de 15.1201 dB obtenue avec l'algorithme développé dans le projet. Les étapes de validation avec l'outil *NLIN Wizard* sont présentées dans la section suivante.

3.2.1.1 Les étapes de validation d'un échantillon de données avec l'outil web *NLIN Wizard*

Les interférences non linéaires sont liées à des données aléatoires transmises sur les canaux d'un système de communication à fibres optiques. Elles sont habituellement traitées comme

du bruit qui limite la capacité de ces systèmes. Dans les travaux de (Dar et al, 2014), les chercheurs s'y réfèrent comme le bruit d'interférence non linéaire NLIN. Ils proposent un modèle semi-analytique qui tient compte du format de modulation et de la pré-distorsion dont dépend la puissance NLIN, afin d'améliorer la précision de l'estimation par le modèle de bruit gaussien GN de cette puissance.

L'outil *NLIN Wizard* calcule la puissance NLIN inter et intra-canal avec les termes de correction tels que dans (Carena et al, 2014). Il permet d'inclure la contribution des mélanges à quatre ondes FWM selon le choix. Et comme recommandé par les auteurs, ces effets ne sont pas pris en compte.

Les étapes consistent à entrer les paramètres de la fibre et de la transmission optiques ; Ensuite de soumettre ces entrées pour obtenir les résultats des calculs de puissance P_{ASE} , P_{NLI} ainsi que l'OSNR en fonction de ces paramètres.

Le fonctionnement de l'outil par le biais de l'estimation de l'OSNR pour la liaison WDM DP-QPSK à 112 Gbits/s à 4 canaux est illustré ci-dessous. La figure 3.2 montre les paramètres d'entrée de la fibre optique tels que mentionnés dans ce chapitre.




The NLIN Wizard interface features a dark header with a green tree logo and the title "NLIN Wizard". Below the header, four professors are listed: Dr. Ronen Dar (Tel Aviv University), Prof. Meir Feder (Tel Aviv University), Prof. Antonio Mecozzi (University of L'Aquila), and Prof. Mark Shtaif (Tel Aviv University). The main content area is titled "Fiber parameters" and contains a table of input fields for various fiber characteristics. Each field has a unit and a help icon (question mark).

Parameter	Unit	Value	Help
Polarization		Dual	?
Nonlinear coefficient	[1/W/km]	1.3	?
Dispersion coefficient	[ps ² /km]	21	?
Fiber loss coefficient	[dB/km]	0.2	?
Span length	[km]	80	?
Number of spans		11	?

Figure 3.2 Paramètres de la fibre en entrée sur l'outil NLIN Wizard
Adaptée de Dar et al (2013)

Les paramètres de la transmission sont décrits dans la figure 3.3 ci-dessous :



The NLIN Wizard interface shows the "Transmission parameters" section. It contains a table of input fields for various transmission characteristics. Each field has a unit and a help icon (question mark). At the bottom, there is a "Submit!" button.

Parameter	Unit	Value	Help
Pulse shape		square-root raised cosine	?
Roll-off factor		0.2	?
Baud-rate	[GHz]	56	?
Channel frequencies	[GHz]	[-100:50:50]	?
Average input powers	[dBm]	[-5 -5 -5]	?
Pre-dispersion values	[ps ²]	zeros(1,4)	?
Modulation format		QPSK	?
Fourth-order modulation factors			?
Sixth-order modulation factors			?
Include FWM effects		☐	?
SNR calculation			
Amplifier noise figure	[dB]	5	?

Submit!

Figure 3.3 Paramètres de la transmission en entrée sur le NLIN Wizard
Adaptée de Dar et al (2013)

Sur la figure 3.4, sont affichés les résultats pour la puissance de bruit d'interférence non linéaire : inter-canal, intra-canal et totale. Et la figure 3.5 montre la puissance de l'émission spontanée amplifiée ainsi que l'OSNR estimés par l'outil.




Figure 3.4 Puissance de bruit d'interférences non linéaires
Adaptée de Dar et al (2013)




Figure 3.5 Puissance de l'émission spontanée amplifiée et OSNR en bleu
Adaptée de Dar et al (2013)

3.2.2 Comparaison avec l'OSNR mesuré sur une liaison WDM 112 Gbit/s à 4 canaux avec compensation optique de la dispersion avec l'outil VPItransmissionMaker

L'outil VPI facilite la conception de nouveaux systèmes et sous-systèmes de transmission optique d'accès, de métro et de longue portée. Il combine une interface graphique puissante,

un planificateur de simulation robuste et des modèles de simulation réaliste associés à des représentations de signaux optiques flexibles à différents degrés d'abstraction afin de modéliser de manière précise et efficace tout système de transmission y compris les liaisons bidirectionnelles, les réseaux en anneau et les réseaux maillés. La simulation détaillée du signal optique dans le domaine temporel permet l'estimation du taux d'erreur binaire BER et l'analyse des diagrammes de l'œil. De plus cette représentation facilite la modélisation efficace de systèmes complexes sans nécessiter de simulations de longue durée. Il est possible d'intégrer des interfaces prédéfinies de MATLAB, Python et de (*Dynamic Link Libraries DLL*) en co-simulation avec l'outil VPI.

Une liaison WDM DP-QPSK à 112 Gbits/s a été conçue dans les travaux de (Uwambajimana, 2016). Ce lien comporte 4 canaux et est utilisé afin de comparer les formules analytiques décrites dans le chapitre 2 et codées dans l'algorithme pour le calcul de l'OSNR et du BER de connexions optiques à partir de plusieurs paramètres. Dans ces travaux, l'auteure a fait une description détaillée de chaque partie du système de transmission optique. L'outil VPI comporte des modèles ayant facilité la conception de cette liaison.

Les paramètres de ce système ont été recueillis pour la comparaison de la valeur de l'OSNR obtenue à partir de l'outil *NLIN Wizard*, ainsi que par l'exécution de l'algorithme de génération des données synthétiques. Ce sont la longueur de *span* de 80 km, la longueur totale de 880 km, l'atténuation de 0.2 dB/km, la dispersion de 16 ps/nm.km et l'aire effective de $80 \times 10^{-12} \text{m}^2$. Aussi, pour la transmission la valeur optimale de la puissance par canal de -5 dBm est considérée. Un OSNR de 15.1201 dB est obtenu avec l'algorithme de génération de données avec une valeur de BER calculée de 2.2×10^{-3} . Il est important de noter que la valeur de l'étiquette pour une telle connexion optique est « bonne QoT » car cette valeur de BER obtenue est inférieure au BER seuil de 4×10^{-3} . Le graphe de la figure 3.13 montre les valeurs d'OSNR calculées à partir des nouveaux paramètres décrivant la liaison WDM DP-QPSK de 112 Gbit/s à 4 canaux, sur l'outil MATLAB.




Figure 3.6 OSNR reçu en fonction de la distance sur une liaison DP-QPSK à 112 Gbit/s et 4 canaux, avec compensation électronique de dispersion à partir de l'algorithme sur MATLAB

Les valeurs d'OSNR obtenues sur l'outil VPI et tirées des travaux de (Uwambajimana, 2016) sont présentées dans la figure 3.7 ci-dessous.




Figure 3.7 OSNR reçu en fonction de la distance sur VPI
pour une liaison compensée DP-QPSK à 112 Gbit/s et 4 canaux
Tirée de Uwambajimana (2016)

Une similitude est observée entre les valeurs d'OSNR obtenues avec l'outil VPItransmissionMaker et celles calculées avec l'algorithme de génération de données synthétiques développé sur MATLAB à partir des différentes formules analytiques présentées dans le chapitre 2. Le tableau 3.1 ci-dessous montre les valeurs d'OSNR obtenus à partir des deux outils :

Tableau 3.1 OSNR en fonction de la distance de transmission

	Algorithme sur MATLAB	VPI
500 km	~18 dB	~18.5 dB
650 km	~17 dB	~17.5 dB
750 km	~16 dB	~17 dB

3.2.3 Comparaison avec l'OSNR obtenu à partir de la formule analytique de calcul d'OSNR final sur une liaison optique

La formule analytique permettant de calculer l'OSNR requis sur une liaison WDM est donnée par :

$$OSNR \approx 58.0 + 10 \log P_{TX} - F - A_S - 10 \log N_{OA} \quad (3.1)$$

La puissance de transmission par canal est en mW. La figure de mérite F et le gain des amplificateurs A_S sont en dB. N_{OA} représente le nombre d'amplificateurs sur la liaison.

Un exemple de calcul d'OSNR à partir de cette formule est proposé :

Pour une liaison WDM de longueur 880 km, avec des *spans* de 80 km, le nombre d'amplificateurs est de 10.

Le gain des amplificateurs est donné par le produit du coefficient d'atténuation qui est de 0.2 dB/km et de la longueur de *span* de 80 km. Soit 16 dB.

La puissance considérée est de -5 dBm et la figure de mérite de 5 dB.

On obtient :

$$OSNR \approx 58.0 - 5 - 5 - 16 - 10$$

Soit OSNR = 22 dB.

Cette valeur est supérieure à celles obtenues avec l'algorithme sur MATLAB, avec le *NLIN Wizard* et avec le VPI pour la liaison compensée. Ceci peut être expliqué par le fait que cette

formule analytique ne tient pas compte des imperfections non linéaires qui affectent le signal, contrairement au modèle de bruit gaussien utilisé dans les algorithmes.

De plus, on peut constater que les valeurs d'OSNR dans une liaison WDM à compensation optique de dispersion sont très proches de celles calculées avec l'algorithme et l'outil *NLIN Wizard*, qui elles sont déterminées pour une liaison WDM à compensation électronique de dispersion.

Une description des trois méthodes d'apprentissage machine choisies pour conduire à la classification de connexions optiques à l'aide la cognition est présentée ensuite, avec les deux méthodes de validation de techniques d'apprentissage machine, la validation croisée à K plis et la mesure de l'erreur présentée à l'aide de matrice de confusion et de la courbe des caractéristiques d'exploitation du récepteur ROC.

3.3 Classification de connexions optiques à l'aide de la cognition

Comme mentionné dans le premier chapitre, l'introduction de la cognition dans les réseaux optiques consiste à y introduire l'intelligence grâce aux algorithmes d'apprentissage machine. Cette intelligence se décrit par la capacité du réseau à observer et apprendre, orienter, décider et agir en prenant en compte de l'environnement et des objectifs de bout en bout, telle qu'indiquée dans la boucle cognitive de la figure 3.8.




Figure 3.8 Boucle cognitive
Adaptée de Miguel et al (2013)

3.3.1 Les méthodes d'apprentissage machine dans les réseaux optiques

L'apprentissage machine suppose un processus de conversion de l'expérience en expertise ou en savoir. Autrement dit, l'entrée d'un algorithme d'apprentissage se compose de données d'apprentissage, représentant l'expérience, et la sortie est une certaine expertise, qui prend généralement la forme d'un autre programme qui peut effectuer une tâche (Shalev-Shwartz & Ben-David, 2014).

La complexité d'un problème donné ainsi que le besoin d'adaptation peuvent nécessiter l'utilisation d'algorithmes d'apprentissage automatique. Dans le cas de l'estimation de la qualité de transmission de connexions optiques, cette complexité se situe au niveau de l'analyse des caractéristiques de liens optiques pour la classification de ces liens. Cette situation requiert de plus une adaptation à ces différentes caractéristiques d'entrée qui sont des paramètres des connexions optiques. Les techniques d'apprentissage machine s'adaptent automatiquement aux données caractéristiques pour une excellente performance de prédiction ou de classification, d'où la proposition de leur utilisation dans le domaine des réseaux optiques.

Types d'apprentissage

Le domaine de l'apprentissage machine se subdivise en plusieurs sous-domaines basés sur les types de tâches d'apprentissage. Plus généralement, on distingue l'apprentissage supervisé et l'apprentissage non supervisé. Le premier décrit un scénario dans lequel les données d'apprentissage sont pourvues d'étiquette, qui est l'information que l'algorithme d'apprentissage machine doit prédire pour les données de test. Dans le second il n'y a pas de distinction entre les données d'apprentissage et de test. Dans ce cas la technique d'apprentissage machine traite les données d'entrée dans le but de trouver une version compressée de ces données. Le regroupement de données en sous-ensembles d'objets similaires appelé « *data clustering* » décrit bien le principe d'apprentissage non supervisé.

Un autre type d'apprentissage, dit intermédiaire existe et selon lequel des machines et des agents de logiciel, déterminent automatiquement le comportement idéal dans un contexte spécifique dans le but de maximiser les performances. Les agents apprennent leur comportement grâce à des données de récompense de scénarios passés recueillies.

D'autres éléments permettent de déceler d'autres types d'apprentissage, tels que les rôles joués par le classificateur ou le protocole d'apprentissage selon lequel le classificateur devrait fournir des réponses tout au long du processus d'apprentissage ou après avoir traité de grandes quantités de données. Dans ce projet, la classification de connexions optiques basée sur la qualité de transmission a nécessité une approche d'apprentissage supervisé.

Les techniques de régression linéaire, logistique et polynomiale, les arbres de décision, les réseaux de neurones, les K plus proches voisins, la forêt aléatoire et la machine à vecteur de support sont les algorithmes d'apprentissage supervisé les plus répandus. L'apprentissage non supervisé compte les techniques « *K-means* », les modèles de Markov cachés ou « *Hidden Markov Models* » et la classification hiérarchique ou « *Hierarchical Clustering* ».

Les deux types d'apprentissage ont été utilisés dans les réseaux optiques de façon à y introduire la cognition. Différents travaux sont présentés dans les sections 1.3 et 1.4 avec les techniques utilisées.

La technique CBR a été la principale méthode utilisée dans le projet européen de réseaux optiques reconfigurables hétérogènes et cognitifs (Caballero et al, 2014). Cette technique permet aux réseaux d'utiliser les expériences passées afin de prédire la qualité de transmission QoT de nouvelles connexions. Ces expériences passées sont conservées dans une base de connaissance (*Knowledge Base*, KB) avec des étiquettes, afin de pouvoir construire des règles ou des modèles pour permettre la classification de nouvelles connexions optiques. (Barletta et al, 2017) ont employé les techniques des K plus proches voisins et la forêt aléatoire pour la classification de connexions optiques avant leur établissement dans le réseau, toujours en se basant sur les paramètres de qualité de transmission.

Dans ce projet, la méthode SVM est étudiée ainsi que ces deux dernières techniques afin d'estimer la qualité de transmission de nouvelles connexions optiques avant leur établissement. Ces algorithmes sont présentés dans la section 3.3.3.

3.3.2 Les méthodes de validation dans les processus de classification et de prédiction

Il existe plusieurs méthodes d'évaluation de techniques de classification en apprentissage machine. Dans cette étude, le modèle généré est dit prédictif car l'objectif est de prédire la classe de nouvelles connexions optiques. Pour ces modèles, plusieurs méthodes de validation sont proposées. Celles utilisées dans cette étude sont : la validation croisée à K-plis (*K-Fold Cross Validation*) selon laquelle l'ensemble des données est divisé aléatoirement en K parties égales. Pour générer chaque paire, l'une des K parties est gardée comme ensemble de validation et les K-1 parties restantes sont combinées pour former l'ensemble d'apprentissage. Ce processus est répété K fois en laissant à chaque fois une partie différente des K divisions égales, de sorte que K paires soient obtenues.

Il est possible de remarquer que la taille de l'ensemble de données de validation doit être infime afin de garder un ensemble de données d'apprentissage grand et aussi que les données d'apprentissage se chevauchent considérablement en se partageant $K-2$ parties. De plus, le pourcentage des données d'apprentissage augmente avec la valeur de K . Ceci permet d'obtenir des estimateurs plus robustes, mais l'ensemble des données de validation devient plus petit, et le coût d'apprentissage du classificateur augmente. Un cas extrême de validation croisée à K plis est le *leave-one-out* dans lequel une seule instance d'une base de N instances de données, est laissée de côté comme donnée de validation et l'apprentissage se fait avec le reste des $N-1$ instances. N paires séparées sont alors obtenues en omettant une instance différente à chaque itération. Ce procédé est généralement utilisé dans des applications où les données étiquetées sont difficiles à trouver.

3.3.2.1 Description et choix des méthodes de validation utilisées

Une validation croisée à 5 plis (*5-Fold Cross Validation*) a été implémentée dans les différents algorithmes. Cette valeur n'affecte pas trop l'apprentissage des algorithmes puisque les résultats obtenus sont en dizaine de secondes et les modèles générés sont très robustes vu les performances de classification obtenues.

Aussi, sous l'hypothèse du *0/1 loss* c'est-à-dire que toutes les erreurs ont un coût égal et que toutes les bonnes décisions n'ont aucune perte associée, les calculs d'erreur sont présentés à l'aide de matrice de confusion, illustrée généralement comme dans la Table 3.1.

Tableau 3.2 Matrice de confusion adaptée de Alpaydin (2010)

Classe réelle	Classe prédite	
	Bonne QoT	Mauvaise QoT
Bonne QoT	VP : Vrai Positif	FN : Faux Négatif
Mauvaise QoT	FP : Faux Positif	VN : Vrai Négatif

Pour chaque technique, cette matrice est proposée en indiquant en ligne la classe prédite et en colonne la vraie classe de chaque instance de la base de test. Les classes sont désignées par les valeurs 0 pour une qualité de transmission non acceptable ($BER > B_{th}$) et 1 pour une bonne qualité de transmission ($BER < B_{th}$).

Le taux d'erreur est calculé selon la formule :

$$Taux\ d'erreur = \frac{|FN| + |FP|}{N} \quad (3.1)$$

avec $N = |VP| + |FP| + |VN| + |FN|$, soit le nombre total des instances de données de test.

Les faux positifs FP représentent les connexions qui ont été prédites de bonne QoT mais qui en réalité sont de mauvaise QoT. Tandis que les faux négatifs FN décrivent les connexions qui ont été prédites de mauvaise QoT alors qu'en réalité elles sont de bonne QoT. Le coût des faux négatifs ou des faux positifs serait évalué selon l'impact de chacune des situations dans un contexte de systèmes optiques en ligne. Des faux négatifs impliqueraient une sous-utilisation des ressources du système optique alors que des faux positifs compromettraient le contrat de niveau de service.

Finalement, la courbe des caractéristiques d'exploitation du récepteur (*Receiver Operating Characteristics*, ROC) est aussi proposée, et qui indique le taux de réussite par rapport au taux de fausse alarme. Pour chaque algorithme de classification, il existe un seuil de décision qui peut être réglé de manière à changer le nombre de vrais positifs par rapport aux faux positifs. Et, augmenter le nombre de vrais positifs augmente également le nombre de fausses alarmes ; diminuer le nombre de fausses alarmes diminue également le nombre de réussite. Cependant cette courbe est utilisée seulement pour analyser les performances de prédiction de la classe pour la technique retenue avec différentes tailles de base de données de test.

3.3.3 Les techniques d'apprentissage machine étudiées

La classification de connexions optiques avant leur établissement se décrit comme un problème d'apprentissage supervisé et les techniques d'apprentissage machine pouvant répondre à cette problématique sont nombreuses. Le choix des algorithmes de classification repose généralement sur divers facteurs tels que la nature des données, la vitesse de convergence, la capacité de généralisation ou la précision. Cependant, ce projet se basant sur les travaux de (Barletta et al, 2017), les techniques des K plus proches voisins et des forêts aléatoires sont reprises dans notre étude par souci de comparaison. La technique des machines à vecteurs de support quant à elle étant un des algorithmes les plus populaires pour établir la frontière entre des classes de données (Alpaydin, 2010), elle paraît un bon choix pour une classification efficace des connexions optiques.

3.3.3.1 La méthode des K plus proches voisins K-NN

La technique K-NN est un des plus simples algorithmes d'apprentissage machine, qui repose sur l'hypothèse que « les choses qui se ressemblent doivent être semblables ». Elle peut être utilisée pour des problèmes de régression ou de classification et fournit de très bons résultats malgré sa simplicité. Dans K-NN, toutes les données d'apprentissage sont stockées pour la recherche et la correspondance de nouvelles instances lors de la prédiction. Une mesure de distance permet de déterminer les K instances dans l'ensemble de données d'apprentissage qui sont les plus semblables aux nouvelles instances d'entrée. Plusieurs mesures de distance existent telles : la distance de Hamming, la distance de Manhattan, la distance de Minkowski et la distance de Mahalanobis, pour ne citer que celles-là.

Dans le cas de problèmes de classification, il convient de considérer les K plus proches voisins qui ont le droit de vote. Ces K plus proches voisins ont tous un vote égal et permettent de déterminer la frontière de décision qui est utilisée pour attribuer la classe aux nouvelles instances. La classe retenue est celle ayant la fréquence la plus élevée parmi les K les plus similaires. La valeur de K est généralement impaire afin de minimiser les confusions entre deux classes voisines. La courbe d'erreur de validation permet de choisir la valeur

optimale de K pour une meilleure frontière de décision, en se basant sur un ensemble de données de validation différent de celui des données d'apprentissage.

Plus grande est la valeur de K , plus grand est le biais mais plus petite est la variance. Alors que plus petite est la valeur de K , plus petit est le biais mais plus grande est la variance. Le biais mesure à quel point les prédictions des modèles sont en général correctes, tandis que la variance mesure à combien les prédictions pour une instance donnée varient entre différentes réalisations d'un modèle. Il faut donc trouver le bon compromis entre le biais et la variance pour un modèle donné et une base spécifique de connaissances.

La figure 3.10 montre les erreurs de classification après une validation croisée à 5 plis en fonction de la valeur de K . La valeur de l'hyper-paramètre K , qui représente le nombre de voisins à considérer pour minimiser l'erreur de classification peut facilement être déduite. Cette valeur est utilisée avec le modèle pour la prédiction de la classe des données de la base de test.

La valeur de K varie de 1 à la racine carrée de la taille totale de la base de connaissances, selon un principe répandu en apprentissage machine. L'erreur de classification est calculée pour les valeurs impaires de K , avec la fonction *kfoldLoss* intégrée dans MATLAB. La plus petite valeur de cette erreur est de 0.1297 et correspond à $K = 3$ comme dans la figure 3.9 ci-dessous.




Figure 3.9 Erreur de validation en fonction de K avant la mise à l'échelle

La mise à l'échelle des données avec la méthode *zscore* permet de réduire l'erreur de classification à 0.038 pour un K optimal de 1. Dans ce cas la classe d'une instance de test est déterminée par similarité avec l'élément d'apprentissage le plus proche. Ce procédé suppose un ensemble de caractéristiques valides pour la prédiction ; d'où la nécessité de valider les données synthétiques. Il est nécessaire de noter cependant, que le temps de traitement augmente dans ce cas.

Cette étape de mise à l'échelle des données avait été omise pour les résultats reportés dans (Aladin & Tremblay, 2018), pour la validation croisée permettant de trouver le K optimal. La figure 3.10 montre clairement que ce procédé a permis d'améliorer la précision de classification de l'algorithme, par contre le temps de traitement a augmenté.




Figure 3.10 Erreur de validation en fonction de K après mise à l'échelle des données

Malédiction de la dimensionnalité

La taille du vecteur de caractéristiques peut grandement affecter la performance de la technique du plus proche voisin K-NN. Lorsque cette valeur augmente, les points peuvent être similaires tout en ayant de grandes distances qui les séparent. C'est le problème de la malédiction de la dimensionnalité, appelé « *Curse of Dimensionality* ».

La base de connaissances compte six (6) caractéristiques principales par instance dont la longueur totale du lien, la longueur de *span*, le nombre de *span*, la puissance de transmission, la modulation et le débit de transmission. Ce problème ne concerne donc pas la base de données générée dans le cadre de cette étude.

3.3.3.2 La méthode des machines à vecteur de support SVM

Les machines à vecteurs de support SVM est un algorithme d'apprentissage supervisé qui peut être utilisé pour des travaux de régression ou de classification. Le principe de cet algorithme consiste à représenter chaque instance de données comme un point dans un espace à n dimensions (n étant le nombre de caractéristiques d'entrée) et où les valeurs des coordonnées correspondent aux valeurs des caractéristiques. La classification est effectuée en trouvant l'hyperplan qui sépare effectivement les deux classes.

Les instances de la base de données doivent être non seulement du bon côté de l'hyperplan mais aussi elles doivent être éloignées de cet hyperplan pour une meilleure généralisation. La marge est la distance entre l'hyperplan et les instances les plus proches de chaque côté. Il faut donc identifier l'hyperplan optimal, qui effectue la meilleure classification et qui maximise la marge. Un hyperplan avec une faible marge conduit à de fortes chances de mauvaise classification. La figure 3.11 ci-dessous décrit un ensemble de données d'apprentissage séparées par deux hyperplans. Le premier en pointillé noir est meilleur que le second en vert, selon le concept de la marge (Shalev-Shwartz & Ben-David, 2014).




Figure 3.11 Marge d'hyperplan
Tirée de Shalev-Shwartz & Ben-David (2014)

L'hyperplan peut être linéaire pour des données facilement séparables dans un espace à deux dimensions. Cependant, l'astuce du noyau ou « *kernel trick* » est la technique proposée par SVM selon laquelle un espace d'entrée de faible dimension est transformé en un espace de dimension supérieure de façon à pouvoir séparer les données du nouvel espace. Cette technique est surtout utilisée dans les problèmes de séparation non linéaire. Après la transformation des données, SVM fait la séparation des données en fonction des étiquettes.

Certains paramètres ont un très grand impact sur la performance du modèle généré par SVM : Le coefficient du noyau pour les noyaux de types « RBF », « Poly » et « Sigmoïde ». Plus la valeur de gamma est élevée, plus l'erreur de généralisation et le problème de sur-ajustement sont importants. Le paramètre de pénalité du terme d'erreur C, qui contrôle le compromis entre la frontière de décision lisse et la classification correcte des instances de données d'apprentissage.

La validation croisée permet de trouver la combinaison efficace du type de noyau, de la valeur de gamma et de celle de C pour éviter le sur-ajustement et assurer une meilleure performance.

Cet ajustement est fait de façon automatique dans l'algorithme, et les meilleurs paramètres sont ensuite utilisés avec le modèle construit afin de prédire la classe exacte des instances de données de la base de test.

Un échantillon de données est présenté dans la figure 3.12, où la vraie classe de chacune des observations peut être distinguée. La figure 3.13 montre la classification des données de test de l'échantillon, réalisée avec les valeurs optimales des hyper-paramètres gamma et C obtenus et le modèle construit.




Figure 3.12 Présentation d'un échantillon de données avec les étiquettes

Dans le graphe des résultats de la classification, les données d'apprentissage sont représentées par les marqueurs non remplis. Tandis que les marqueurs remplis représentent les observations de test avec les couleurs qui délimitent les classes que le modèle SVM assigne à chaque instance. Les couleurs de bord représentent la classe réelle de chaque observation.




Figure 3.13 Classification d'un échantillon de connexions optiques avec SVM avec noyau RBF

Dans l'algorithme SVM développé, le noyau (*Radial Basis Function*, RBF) est gardé pour la construction du modèle. L'optimisation se fait donc au niveau des hyper-paramètres gamma et C, trouvés à l'aide de la méthode de validation croisée à 5 plis comme pour le K-NN. Ceci se fait dans l'idée de construire un modèle moins rigide, selon le principe de marge souple ou *soft margin*, proposé par (Cortes & Vapnik, 1995) : il permet d'ignorer ou de placer certains éléments du mauvais côté de la marge pour un meilleur ajustement global du modèle.

Le paramètre gamma définit l'étendue de l'influence d'une seule instance d'apprentissage, de sorte qu'une valeur faible implique une grande variance donc une plus grande influence. C'est-à-dire si l'instance concernée est un vecteur de support, sa classe influence le choix de la classe des éléments même si la distance entre ce vecteur de support et l'élément est grande. Et si gamma est grand, la variance est alors faible et l'influence du vecteur de support est

donc réduite. Pour résumer, une valeur élevée de gamma conduit à des modèles à faible variance et biais élevés, et vice-versa.

Le paramètre C est une fonction qui contrôle l'influence de chaque vecteur de support et se définit comme le coût de la marge souple. Lorsque ce paramètre est faible, la frontière de décision est dite lisse tandis qu'un C grand vise à classer correctement toutes les instances d'apprentissage en donnant au modèle la liberté de sélectionner plus d'instances comme vecteurs de support. Le processus d'optimisation de cet hyper-paramètre implique un compromis entre l'erreur et la stabilité du modèle.

L'implémentation de l'étape de validation croisée à 5 plis conduit à un gamma égal à 64 et un coût C égal à 0.088388 comme meilleurs paramètres conduisant à une précision de classification des données d'apprentissage de 98.0711%.

Les valeurs des paramètres d'optimisation du modèle construit sont ensuite utilisées avec le classificateur afin de prédire la classe des données de test. La précision de classification est estimée selon une comparaison entre l'étiquette réelle stockée dans l'ensemble des données de test et celle prédite par la technique. Les résultats sont présentés et analysés dans le chapitre 4.

3.3.3.3 La méthode des forêts aléatoires (RF)

La technique des forêts aléatoires est une méthode d'apprentissage machine capable d'effectuer une régression et la classification. Elle peut aussi être utile pour la réduction de dimension. C'est une méthode d'apprentissage d'ensembles, c'est à dire une technique où des modèles dits faibles sont combinés pour former un modèle plus puissant.

Le RF peut être utilisé pour des bases de données avec une taille énorme. Il permet à un nombre élevé d'observations de participer à la prédiction. Plusieurs arbres sont considérés,

contrairement au seul arbre dans le modèle d'arbres de classification et de régression (*Classification And Regression Trees*, CART). Pour classer une nouvelle instance, chaque arbre donne une classification en votant pour cette classe. La forêt choisit la classification ayant le plus de votes sur l'ensemble des arbres de la forêt.

Les données sont divisées en données d'apprentissage et de test. Dans la méthode RF, les données de test sont appelées échantillons hors sac ou (*Out of Bag*, OOB). L'erreur estimée sur ces données de test est l'erreur OOB qui est utilisée dans cette étude de performance pour cet algorithme.

Dans cette étude, la fonction *Treebagger* intégrée dans MATLAB est considérée pour implémenter la technique de forêt aléatoire de (Breiman, 2001). Cela se fait à partir du paramètre *NumPredictorsToSample* qui a pour valeur par défaut la racine carrée du nombre d'éléments du vecteur de caractéristiques dans le cas d'une classification.

Le nombre d'estimateurs est fixé à 100, comme dans les travaux de (Barletta et al, 2017). Le nombre minimum d'observations par feuille d'arbre est égal à 1 pour la classification de données, contrairement à la valeur 5 dans le cas d'une régression.

La figure 3.8 présente le graphe de l'arbre de classification d'un échantillon de 200 instances de données de la base de connaissances avec le modèle construit. Les deux variables longueur totale et puissance de transmission sont les variables choisies pour ce graphique. Les variables X1 et X2 du graphe correspondent aux deux caractéristiques qui conduisent à la classification des observations de connexions optiques avec la technique RF et 100 estimateurs.




Figure 3.14 Arbre de classification d'un échantillon de 200 connexions optiques avec RF et 100 estimateurs

Les résultats de performance telle la précision de la classification et le temps de traitement pour la technique de forêt aléatoire RF sont aussi analysés dans le chapitre 4 du document.

3.3.4 Choix d'algorithme de classification et de prédiction de la QoT selon les critères de performance

Les techniques d'apprentissage machine supposent la génération de modèles ou classificateurs qui dépendent des données d'apprentissage. Des tests statistiques permettent d'évaluer le taux d'erreur attendu d'un algorithme de classification et de comparer les taux d'erreur attendus de deux ou plusieurs algorithmes de classification afin de déceler lequel offre la meilleure performance. Dans cette section, une revue des tests d'évaluation et de comparaison des taux d'erreur est proposée.

Trois algorithmes de classification sont étudiés dans ce projet et les trois sont applicables au scénario d'estimation de la qualité de transmission QoT de connexions optiques. Il convient donc de décider lequel des trois algorithmes offre une meilleure performance en termes

d'erreur de classification. Cela peut se faire par l'utilisation d'un ensemble de données de validation différent de celui des données d'apprentissage.

Avec à l'esprit le théorème (*No Free Lunch*), une comparaison des différents algorithmes de classification appliqués sur une même base de données - car les résultats sont conditionnés par celles-ci - est réalisée. De plus, le résultat obtenu est seulement vrai pour l'application particulière représentée. Pour tout algorithme d'apprentissage, il existe un ensemble de données pour lequel il est très précis et un autre pour lequel il est très pauvre. Il n'existe donc pas de meilleur algorithme d'apprentissage. Et dire qu'une technique d'apprentissage machine performe bien revient à quantifier à quel point son biais inductif correspond aux propriétés des données (Wolpert, 1996).

La division de la base de connaissances en données d'apprentissage et de validation est nécessaire pour déterminer les hyper-paramètres qui forment le modèle final. Ensuite ce modèle est comparé avec les autres sur la base du taux d'erreur attendu.

Il faut noter toutefois que le taux de précision de classification de ces techniques d'apprentissage machine n'est que l'un des nombreux critères pouvant décrire leur performance. Il y a aussi le temps d'apprentissage, le temps de test, l'intelligibilité qui permet une extraction des connaissances qui peuvent être vérifiées et validées par des experts. Les importances relatives de ces critères changent en fonction de l'application. L'emphasis est mise sur la précision de classification, le temps de test et l'évolutivité. Ce dernier facteur est analysé dans cette recherche, cependant les deux premiers sont les plus importants dans le cadre de l'estimation de la qualité de transmission de connexions optiques.

Aussi, une fois la base de connaissances divisée et les critères de performance établis, Il convient de choisir les méthodes de validation à utiliser pour pouvoir effectuer l'analyse de performance pour le choix de la technique que proposée dans l'outil.

3.4 Conclusion

L'apprentissage machine est un outil puissant utilisé dans divers domaines parce que c'est le moyen le plus répandu qui permet de générer des recommandations, à partir de données valides. La qualité des données peut grandement affecter l'efficacité des algorithmes d'apprentissage machine vu le principe de fonctionnement de ces algorithmes, qui consiste à tirer des conclusions en se basant sur un ensemble de données.

La validation des données synthétiques permet de s'assurer que les classificateurs construits sont robustes et qu'ils peuvent être appliqués à des données de terrain pour des connexions dans des réseaux optiques existants.

Cette étape n'est pas nécessaire dans le cas de données de terrain provenant de systèmes de transmission optique implantés. Cependant, il existe des solutions permettant de vérifier la qualité des données afin de profiter des avantages offerts par les techniques d'apprentissage machine.

CHAPITRE 4

RÉSULTATS ET DISCUSSION

Dans cette section une analyse des résultats obtenus est proposée pour chacune des trois techniques d'apprentissage machine décrites dans le chapitre 3. Aussi une comparaison de ces résultats est présentée afin de pouvoir choisir la technique appropriée répondant aux exigences de l'outil cognitif d'estimation de la qualité de transmission (QoT) de connexions optiques avant leur établissement. Ces exigences se traduisent par les critères de performance retenus comme les plus importants dans le cadre de cette étude.

4.1 Analyse de performance de chacune des techniques d'apprentissage machine

Le domaine des réseaux optiques est confronté à des niveaux accrus d'hétérogénéité qui se traduisent par les multiples types de services et technologies de transmission. La cognition est la solution pour assurer la gestion efficace des ressources de ces réseaux hautement hétérogènes tout en répondant aux exigences de la qualité de transmission.

Dans le projet CHRON, cette cognition est introduite dans les réseaux optiques à l'aide de la technique d'apprentissage machine CBR. Cette technique conduit à des précisions de classification de l'ordre de 99%. Cependant il convient de noter que le CBR ne construit pas de modèle à priori à partir des données de la base de connaissance, il effectue des recherches en temps réel dans cette base à chaque requête d'évaluation de la QoT, ce qui affecte le temps de traitement en rapport à la taille de la base de connaissances (Caballero et al, 2014).

Comme précisé dans le chapitre 3, le taux de précision de classification des techniques d'apprentissage machine est l'un des critères de performance importants pris en compte dans cette étude. Les deux autres critères considérés dans le cadre du développement de l'outil d'estimation de la qualité de transmission QoT de connexions optiques sont le temps de test et l'évolutivité.

Les trois techniques d'apprentissage machine qui sont analysées dans ce projet construisent chacune un modèle à priori, c'est-à-dire avant le fonctionnement en ligne, en utilisant les données de la base de connaissances. Ce qui signifie qu'une fois le modèle construit, ils requièrent un temps de test - pour prédire la classe des données de test – relativement faible. Donc, hormis la technique K-NN, à l'instar des classificateurs Bayes ou des arbres de décision, les deux autres classificateurs sont beaucoup plus rapides que l'approche CBR : un temps de traitement d'environ 22.4 millisecondes est obtenu pour la prédiction de la classe d'une observation de test avec le modèle RF généré pour une base de connaissances de 15,000 instances. Ce temps est inférieur aux 35 ms prises par le CBR (Caballero et al, 2014).

Il est important aussi de noter qu'avec les 10 estimateurs au lieu des 100 utilisés dans le projet, la précision est faiblement affectée, comme on peut le voir sur la figure 4.1 ci-dessous. Cependant, d'une manière générale, la fiabilité des estimations obtenues avec les prédictions hors sac OOB, augmente avec le nombre d'estimateurs. L'erreur hors sac à partir de 8 estimateurs se rapproche de la valeur obtenue avec les 100 estimateurs. Elle diminue pour des valeurs moindres.




Figure 4.1 Erreur de classification hors sac
avec RF et 10 estimateurs

Dans le cas de SVM, le temps de prédiction de la classe pour une seule observation, utilisant une base de connaissances d'environ 15,000 instances pour la génération du modèle, devient 0.885 millisecondes, qui est nettement inférieur au temps de traitement de la méthode CBR.

4.2 Comparaison des résultats des différentes méthodes

La comparaison des trois algorithmes d'apprentissage machine se base sur les deux métriques de précision de prédiction de la classe et du temps de traitement pour cette prédiction. L'évolutivité est ensuite étudiée pour la technique la plus performante, avec les différentes tailles d'ensemble de données.

Les simulations sont effectuées sur une machine CentOS Linux 7 utilisant un processeur Intel Core i7-4700MQ avec une mémoire RAM de 7.5 GB.

K-Nearest Neighbor

La technique des K plus proches voisins K-NN fournit une classification des données de test en 4.458 secondes, après la mise à l'échelle des données avec la méthode *zscore* à l'étape d'optimisation de l'hyper-paramètre K qui vaut 1 dans ce cas de figure. Et l'erreur de prédiction devient 0.033 pour une précision de 96.7%. Cette valeur est supérieure à celle obtenue lors de l'étape de la validation croisée à 5 plis décrite dans le chapitre 2. La matrice de confusion obtenue est présentée dans la figure 4.2 ci-dessous :

Classe prédite	1 (Bonne QoT)	3,712	5,051
	0 (mauvaise QoT)	13,784	493
		0 (mauvaise QoT)	1 (Bonne QoT)
		Classe réelle	

Figure 4.2 Matrice de confusion de la technique K-NN

Random Forest

La technique des forêts aléatoires fournit quant à elle une précision de classification des données de test égale à 96.32%. Ce processus de prédiction de la classe des données de test avec le modèle construit à partir de la méthode *treebagger* s'étale sur un temps de traitement de 0.83 seconde. La matrice de confusion de la technique RF est présentée dans la figure 4.3 et décrit bien le nombre d'instances dont les classes sont prédites correctement, de même que celles pour lesquelles la technique performe pauvrement.

Classe prédite	1 (Bonne QoT)	474	5,070
	0 (mauvaise QoT)	17,123	373
		0 (mauvaise QoT)	1 (Bonne QoT)
		Classe réelle	

Figure 4.3 Matrice de confusion de la technique RF avec 100 estimateurs

Support Vector Machine

La précision de prédiction de la classe pour les 23,040 instances de données de la base de test atteint les 99.15% avec la technique des machines à vecteurs de support SVM. Ce classificateur fournit ce résultat sur une durée de 1.26 secondes. Gardons en tête que ce temps n'inclut pas la durée d'apprentissage des données pour la construction du modèle et l'optimisation des hyper-paramètres gamma et C. Les résultats de la performance du classificateur SVM avec les données de test sont présentés dans la figure 4.4 suivante :

Classe prédite	1 (Bonne QoT)	99	5,445
	0 (mauvaise QoT)	17,399	97
		0 (mauvaise QoT)	1 (Bonne QoT)
		Classe réelle	

Figure 4.4 Matrice de confusion de la technique SVM

Discussion

Trois métriques sont généralement utilisées pour évaluer les classificateurs : la précision de la classification, le temps de traitement des données et l'évolutivité. Les matrices de confusion des trois techniques d'apprentissage machine montrent la précision de classification obtenue par chaque classificateur considéré dans ce travail. Les colonnes de la matrice décrivent les classes binaires réelles des instances de test alors que les lignes sont les classes prédites par chaque classificateur. Les faux positifs (les instances prédites de "bonne QoT" alors que la classe réelle est "mauvaise QoT") et les faux négatifs (instances prédites de "mauvaise QoT" alors que la classe réelle est "bonne QoT") permettent de calculer les performances de prédiction de chaque classificateur. À partir des matrices de confusion représentées sur les figures 4.1, 4.2 et 4.3, il est possible de voir que SVM fournit les meilleures performances, avec une précision de classification de 99,15% (22,844 / 23,040), contre 96,32% pour RF et 96.7% pour K-NN. Le taux d'erreur, défini comme le pourcentage de classifications erronées, varie de 3,67% pour RF à 3.33% pour K-NN et 0,85% pour SVM. La technique SVM atteint un très faible taux d'erreur de faux positifs (0,43%), ce qui est comparable à ce qui a été obtenu en utilisant la CBR (Caballero et al, 2014).

En plus de la précision de classification de 99.15% de l'algorithme, le temps de calcul de 1.26 secondes, atteint par SVM pour un ensemble de données de 23,040 instances est plus grand que les 35 ms obtenues en utilisant la technique CBR mais plus faible que les 3,6 s atteints en utilisant le Q-Tool pour une base de données de moins de 15,000 instances, ce qui montre l'avantage d'utiliser la cognition avec la technique SVM dans le processus d'estimation de la qualité de transmission QoT (Caballero et al, 2014).

Pour l'analyse de l'évolutivité du classificateur SVM, la base de connaissances est divisée en plusieurs ensembles de tailles différentes allant de 1000 à 25,600 instances, pour lesquels la probabilité P_{pos} que les connexions optiques de la base de données de test soient de bonne qualité de transmission est estimée. Cette probabilité est tirée de la valeur de score calculée à partir de la méthode *predict* intégrée dans MATLAB. La courbe de caractéristiques de fonctionnement de récepteur ROC permet de visionner la surface sous la courbe (*Area Under the Curve*, AUC) pour les différentes bases de données. Et la plus grande valeur est obtenue pour l'ensemble de 1000 instances et vaut 0.9909. Tandis que cette métrique vaut 0.9743, 0.9658 et 0.9655 pour les ensembles de 5000, de 15,000 et de 25,600 instances. Ces résultats suggèrent un problème d'évolutivité pour le classificateur SVM construit, qui nécessite une étude plus approfondie. Ils sont présentés à l'aide des courbes de la figure 4.5 ci-dessous :




Figure 4.5 Courbes ROC de la technique SVM pour différentes tailles de bases de données

4.3 Conclusion

Ce chapitre expose et analyse les résultats obtenus à partir des différentes techniques d'apprentissage machine étudiées. Et cette analyse permet de déceler, en se basant sur un compromis entre les métriques de précision et de temps de traitement, le classificateur à retenir pour la proposition d'outil cognitif d'estimation de la qualité de transmission (QoT) de nouvelles connexions optiques dans un réseau optique hétérogène.

Selon l'analyse des résultats, le temps de traitement élevé de la technique K-NN peut s'expliquer du fait que l'étape d'apprentissage dans cet algorithme se réduit à une simple mémorisation des données d'apprentissage. Dans ce cas, la prédiction consiste à calculer la distance euclidienne entre les nouvelles instances et toutes les données de la base de données d'apprentissage, pour ensuite attribuer la classe votée par la majorité des K plus proches

voisins sélectionnés. Plus précisément, il attribue à la nouvelle instance la classe de l'observation qui lui est la plus similaire.

La précision de classification obtenue avec l'algorithme des K plus proches voisins (K-NN) est proche de celle obtenue avec l'algorithme de forêt aléatoire (RF). Cependant, le RF serait préféré au K-NN car le temps de traitement est bien plus faible pour le premier. L'algorithme des machines à vecteur de support (SVM) fournit une précision plus élevée que ces deux algorithmes avec un temps de traitement compris entre celui des deux autres techniques.

L'analyse de performance de l'algorithme SVM est aussi présentée avec des ensembles de données de tailles différentes et les résultats montrent un problème avec l'évolutivité.

CONCLUSION

La prise en charge de différents types de services, des formats de modulation avancés et des débits différents dans les réseaux optiques hétérogènes, fait augmenter les défis dans l'évaluation de la qualité de transmission des connexions optiques. La cognition est proposée pour prédire la QoT de trajets optiques non-établis en implémentant dans le système de contrôle de réseau un processus de prise de décision basé sur des techniques d'apprentissage machine, qui stocke des scénarios passés dans une base de connaissances pour l'apprentissage et la construction de classificateur.

La QoT de connexions optiques peut être exprimée par différentes métriques telles que le rapport signal sur bruit optique OSNR, le facteur Q, la magnitude du vecteur d'erreur EVM, le diagramme de l'œil et le taux d'erreur binaire BER. Les modèles analytiques utilisés pour l'estimation de la QoT requièrent généralement un temps de traitement élevé. Par conséquent, la prédiction en temps réel de la qualité du signal de nouvelles connexions optiques avant leur établissement vise à améliorer le processus d'estimation de la qualité de transmission en termes de vitesse et de précision

Dans leurs travaux, (Barletta et al, 2017) proposent une méthode d'estimation de la qualité de transmission dans laquelle le rapport signal sur bruit optique est calculé en fonction de la puissance du canal, des gains et des pertes sur le lien. Dans le modèle analytique utilisé dans cette étude, les dégradations non linéaires et le format de modulation sont pris en compte à l'aide de marges et de pénalités. Et dans (Caballero et al, 2012), la méthode de raisonnement par cas CBR est proposée pour l'estimation de l'OSNR et de l'EVM pour les canaux au format de multiplexage de polarisation en quadrature de phase QPSK dans des liaisons à compensation de dispersion. Dans cette solution, les chercheurs utilisent une base de connaissances de 153 instances obtenues à partir de mesures effectuées pour la configuration considérée. Ils obtiennent des précisions de classification allant de 79 à 98.7%.

La solution proposée dans ce projet se base sur des données synthétiques générées à partir de modèles analytiques tenant compte des imperfections non linéaires. Un échantillon de ces données est choisi au hasard et validé à l'aide de l'outil web *NLIN Wizard* développé par (Dar et al, 2014), tel que détaillé dans la section 3.3.1. Aussi, le chapitre 3 présente une comparaison avec la mesure sur l'outil VPI de l'OSNR d'un exemple de liaison à compensation optique de dispersion, qui a été analysé dans les travaux de (Uwambajimana, 2016). Un écart de seulement 0.38 dB a été constaté entre la valeur d'OSNR retenue dans les travaux sur VPI pour le système cohérent DP-QPSK à 112 Gbit/s WDM à compensation optique de dispersion et celle de l'algorithme proposé pour un système similaire mais avec une compensation électronique de la dispersion. Cette valeur est plus proche de l'OSNR obtenu sur le *NLIN Wizard*, avec un écart de 0.04 dB. Une comparaison finale de ces valeurs avec celle calculée à partir de la formule analytique de l'OSNR final sur une liaison a permis d'identifier l'importance d'introduire les effets non linéaires dans la détermination de ce paramètre de qualité de transmission.

Le modèle de bruit gaussien décrit par (Poggiolini et al, 2014) a été utilisé pour le calcul du rapport signal sur bruit optique. L'algorithme de génération de données a permis d'estimer le taux d'erreur binaire BER en fonction du rapport de l'énergie par bit à la densité spectrale de puissance de bruit E_b/N_0 , le débit ainsi que le format de modulation. Les trois techniques K-NN, RF et SVM ont été appliquées à ces données afin de prédire la QoT de nouvelles connexions optiques en fonction des paramètres de la liaison ainsi que du signal. Les résultats obtenus montrent que l'algorithme SVM surpasse les deux autres techniques K-NN et RF et peut être utilisé avec succès pour l'estimation de la qualité de transmission de connexions optiques.

Les performances de la classification des connexions optiques à l'aide de la technique SVM affichent une précision de 99.15%. Ce résultat est supérieur aux 98.7% obtenus avec la méthode CBR dans le cadre de la démonstration expérimentale de l'outil d'estimation de la qualité de transmission développé dans le projet CHRON (Caballero et al, 2012). Et cette précision de classification dépasse les 96% obtenus avec l'outil E-Tool utilisant la technique

RF (Rottondi et al, 2018). Ces résultats montrent les potentiels avantages de la cognition pour évaluer la qualité de transmission de connexions optiques.

RECOMMANDATIONS

Cette étude a permis de comparer trois techniques d'apprentissage machine pour le développement d'un outil cognitif d'estimation de la qualité de transmission QoT de nouvelles connexions optiques avant leur établissement dans un réseau.

La technique des machines à vecteurs de support SVM offre le meilleur compromis entre la précision de classification et le temps de prédiction de la classe des nouvelles instances de la base de données de test. Notons que le temps d'apprentissage n'est pas pris en compte dans l'analyse de performance de la solution. La phase d'apprentissage permet de trouver les hyper-paramètres et de construire le meilleur classificateur pour chaque technique.

Pour la solution proposée dans le cadre de ce projet, les paramètres C et γ avec le noyau RBF dans l'algorithme SVM sont réglés. D'autres réglages sur la configuration du noyau ou sur les différentes mesures de distances autres que la distance euclidienne par défaut, pourront permettre de vérifier leur impact sur la performance de la méthode des machines à vecteurs de support.

De plus, l'évolutivité par rapport à la taille des ensembles de données à classer reste un aspect à approfondir parce que dans cette étude, la métrique de surface sous la courbe AUC obtenue diminue inversement avec la taille des bases de données de test pour lesquelles le classificateur SVM prédit la classe. Une approche proposée dans le projet CHRON, consiste à incorporer dans le modèle des stratégies d'apprentissage et d'oubli dans le but d'optimiser la base de connaissances en réduisant sa taille. Ceci contribue à réduire le temps de traitement lors de la classification de nouvelles connexions optiques. Cette approche pourra être testée dans l'algorithme développé, en faisant varier le ratio de division de la base de données dans la constitution des ensembles de données d'apprentissage et de test, et ensuite en analysant, pour des bases de données de test de tailles différentes, les résultats obtenus avec les tailles de base de données d'apprentissage.

Dans ce projet, des données synthétiques générées en se basant sur des modèles analytiques très utilisés dans le domaine sont considérées. Cependant, l'utilisation de données de terrain sur des mesures de BER pour la construction du modèle de classification pourra être effectuée.

De plus, certaines techniques d'optimisation des méthodes d'apprentissage machine peuvent être appliquées tant aux bases de connaissances qu'aux algorithmes afin d'augmenter la précision de prédiction de la classe de nouvelles connexions optiques et de réduire le temps de traitement de ces données (Jiménez et al, 2012).

ANNEXE I

ALGORITHME DE GÉNÉRATION DE DONNÉES SYNTHÉTIQUES DE CONNEXIONS OPTIQUES

Dans cette section, l'algorithme de génération des données avec les formules analytiques permettant de calculer l'OSNR en fonction de la puissance de transmission par canal, des puissances d'émission spontanée amplifiée et d'interférence non linéaire, est proposé. Le BER est déterminé à partir de l'E_b/N₀.

```
tic;
```

```
clc;
```

```
close all;
```

```
clear;
```

```
%%%Déclaration des variables%%%
```

```
h = 6.6260 * 10^(-34);    %%Cte de Planck
```

```
alpha_db = 0.22;         %%Atténuation
```

```
F = 10^(5/10);           %%Figure de mérite des amplis
```

```
nu = 1.9350E+14;         %%Fréquence Centrale
```

```
Bn = 32E+9;              %%Bande passante de bruit égale a Rs
```

```
Bref = 12.5;             %%Bande de référence en GHz (@ 0.1 nm)
```

```
gamma = 1.3;             %%Coefficient de Nonlinéarité
```

```
beta = 21E-24;           %%1.27*D squared picosecond ***absolute value
```

```
Nch = 9;                 %%9 canaux
```

```
Rs = 32E+9;              %%Taux de symboles
```

```
T = 4E-3;                %%Seuil BER avec FEC
```

```
%nu2 = 1.9350;
```

```
%beta2 = 21;
```

```
%Rs2 = 32;
```

```
DataRate = [1 2]; %1=50; 2=100; 8=400; 12=600 Gbps
```

```
alpha = alpha_db/4.343;
```

```
DataRate = DataRate.*50; % Conversion en Gb/s
```

```
pp = 1;
```

```
Ltot = linspace(150, 7500, 50); % Ltot de 150 à 7500 km
```

```
Ls = [80 100 120 150]; % Ls dans 80, 100, 120, 150 km
```

```
Pdbm = linspace(-10, 5, 16); %Puissance en dBm -10 à 5
```

```
M = [2 4 16 64]; %M = 2^(1, 2, 4, 6) (BPSK, QPSK, 16QAM, 64QAM) for log2(M) or 1 à 6 bits/symbol
```

```
for i = 1:length(Ltot)
```

```
    for j = 1:length(Ls)
```

```
        Ns(i,j) = Ltot(i)/Ls(j);
```

```
        loss(i,j) = alpha_db.*Ls(j);
```

```
        As(i,j) = 10^(loss(i,j)/10);
```

```
        Leff(i,j) = (1 - exp(-alpha.*Ls(j)))/alpha;
```

```
    for s = 1:length(Pdbm)
```

```
        Ptx1(i,j,s) = 10^(Pdbm(s)/10); %Puissance en milliwatt
```

```
        Ptx(i,j,s) = Ptx1(i,j,s).*1E-3; % Puissance en Watt
```

```
        %%%%%%%%%Puissance ASE and NLI en Watts
```

```
        Pase(i,j,s) = Ns(i,j).*F.*(As(i,j)-1).*h.*nu.*Bn;
```



```

Pnli(i,j,s)
(8/27).*Ns(i,j).*(gamma^2).*Leff(i,j).*(Ptx(i,j,s).^3).*Bn*log((pi^2).*beta.*Leff(i,j).*((Nch
*Rs)^2))/(pi*beta*(Rs^3));

```

```

for l = 1:length(M)

```

```

Margin(i,j,s,l) = 2.5*(M(l) <= 4) + 1.5*(M(l)>4);

```

```

%%%%%%Conversion en milliWatts!!! Puis en dBm

```

```

Pasedb(i,j,s,l) = 10*log10(Pase(i,j,s).*1E+3);

```

```

Pnlidb(i,j,s,l) = 10*log10(Pnli(i,j,s).*1E+3)-Margin(i,j,s,l);

```

```

Pnli_margin1(i,j,s,l) = 10^(Pnlidb(i,j,s,l)/10); %MilliWatts

```

```

Pnli_margin(i,j,s,l) = Pnli_margin1(i,j,s,l).*1E-3;

```

```

%%%%%%OSNR accumulé

```

```

OSNR(i,j,s,l) = Ptx(i,j,s)/(Pase(i,j,s) + Pnli_margin(i,j,s,l));

```

```

OSNRdb(i,j,s,l) = 10*log10(OSNR(i,j,s,l));

```

```

%%%%%% BER au récepteur

```

```

for r = 1:length(DataRate)

```

```

EbNo(i,j,s,l,r) = OSNRdb(i,j,s,l)-10*log10(log2(M(l)))-
10*log10(DataRate(r)/(2*log2(M(l))))/Bref;

```

```

EbNolin(i,j,s,l,r) = 10.^(EbNo(i,j,s,l,r)/10);

```

```

if M(l) == 2 %4 16 64

```

```

% BER(i,j,s,l,r) = BERcalculation(EbNo(i,j,s,l,r), M(l));

```

```

BER(i,j,s,l,r) = 0.5*erfc(sqrt(EbNolin(i,j,s,l,r)));

```



```
        end
    end
end
end
save Final_DB Data_all Labels

toc
```


ANNEXE II

ALGORITHME SVM AVEC VALIDATION CROISÉE À 5 PLIS ET CLASSIFICATION DE DONNÉES DE TEST

La librairie *libsvm* développée par (Chih-Chung Chang et Chih-Jen Lin, 2011) est utilisée afin de développer l'algorithme SVM pour la classification des données de connexions optiques générées à l'aide de l'algorithme décrit en annexe I précédente.

%Algorithme SVM basé sur les simulations développées sur le site web
%https://sites.google.com/site/kittipat/libsvm_matlab

% Ce programme permet d'appliquer la technique SVM à un échantillon de données de 1500
% connexions optiques de la base « Final_DB » générée avec les étiquettes.

% Le code divise les données en deux parties.

% train: 1051 to 1500

% test: 1:1050

% Des graphes permettent de comparer les classes résultantes avec les classes réelles des
% observations.

clear; clc; close all

load Final_DB

%de la base Final_DB générée avec les étiquettes.

conn_label = Labels(1:1500,1);

conn_inst = Data_all(1:1500,1:6);

[N D] = size(conn_inst);

% =====

```
% Determine the train and test index
```

```
trainIndex = zeros(N,1); trainIndex(1051:N) = 1;
```

```
testIndex = zeros(N,1); testIndex(1:1050) = 1;
```

```
trainData = conn_inst(trainIndex==1,:);
```

```
trainLabel = conn_label(trainIndex==1,:);
```

```
testData = conn_inst(testIndex==1,:);
```

```
testLabel = conn_label(testIndex==1,:);
```

```
% =====Mise à l'échelle des données=====
```

```
trainData = zscore(trainData);
```

```
testData = zscore(testData);
```

```
%%=====Validation croisée à 5 plis pour trouver les hyper-paramètres=====
```

```
%%%
```

```
% #####
```

```
% Automatic Cross Validation
```

```
% Parameter selection using n-fold cross validation
```

```
% #####
```

```
stepSize = 10;
```

```
bestLog2c = 1;
```

```
bestLog2g = -1;
```

```
epsilon = 0.005;
```

```
bestcv = 0;
```

```
Ncv = 5;          % Nombre de plis pour la validation croisée
```

```
deltacv = 10^6;
```

```
while abs(deltacv) > epsilon
```

```
    bestcv_prev = bestcv;
```

```
    prevStepSize = stepSize;
```

```
    stepSize = prevStepSize/2;
```

```

log2c_list = bestLog2c-prevStepSize:stepSize/2:bestLog2c+prevStepSize;
log2g_list = bestLog2g-prevStepSize:stepSize/2:bestLog2g+prevStepSize;

numLog2c = length(log2c_list);
numLog2g = length(log2g_list);
cvMatrix = zeros(numLog2c,numLog2g);

for i = 1:numLog2c
    log2c = log2c_list(i);
    for j = 1:numLog2g
        log2g = log2g_list(j);
        cmd = ['-q -c ', num2str(2^log2c), ' -g ', num2str(2^log2g)];
        cv = get_cv_ac(trainLabel, trainData, cmd, Ncv);
        if (cv >= bestcv),
            bestcv = cv; bestc = 2^log2c; bestg = 2^log2g;
        end
    end
end

deltacv = bestcv - bestcv_prev;

end

disp(['The best parameters, yielding Accuracy=',num2str(bestcv*100),'%, are:
C=',num2str(bestc),' , gamma=',num2str(bestg)]);
%%

% % Graphe des résultats
figure;
imagesc(cvMatrix); colormap('jet'); colorbar;
set(gca,'XTick',1:numLog2g)
set(gca,'XTickLabel',sprintf('%3.1f',log2g_list))

```

```

xlabel('Log_2\gamma');
set(gca,'YTick',1:numLog2c)
set(gca,'YTickLabel',sprintf('%3.1f',log2c_list))
ylabel('Log_2c');

% #####
% Phase de test
% Utilise les hyper-paramètres pour classer les données de test
% #####
% tic;
param = ['-q -c ', num2str(2^bestLog2c), ' -g ', num2str(2^bestLog2g), ' -b 1'];
bestModel = svmtrain(trainLabel, trainData, param);
% toc;
% modèle SVM pour classer les données et temps de prédiction des classes
tic;
[predict_label, accuracy, probab_values] = svmpredict(testLabel, testData, bestModel, '-b 1');
toc;

%%====Fin de CV à 5 plis et classification de données test=====

% =====
% ===== Affichage des résultats =====
% =====

% Assignment de couleur pour les classes
colorList = generateColorList(8);
% colorList = prism(100);

% Vraies classes

```



```

trueClassIndex = zeros(N,1);
trueClassIndex(conn_label==1) = 1;
trueClassIndex(conn_label==0) = 2;
colorTrueClass = colorList(trueClassIndex,:);
resultClassIndex = zeros(length(predict_label),1);
resultClassIndex(predict_label==1) = 1;
resultClassIndex(predict_label==0) = 2;
colorResultClass = colorList(resultClassIndex,:);

```

% Réduction de la dimension à 2D

```

distanceMatrix = pdist(conn_inst,'euclidean');
newCoor = mdscale(distanceMatrix,2);

```

% Graphe de l'ensemble des données de l'échantillon

```

x = newCoor(:,1);
y = newCoor(:,2);
patchSize = 30;
colorTrueClassPlot = colorTrueClass;
figure; scatter(x,y,patchSize,colorTrueClassPlot,'filled');
title('Echantillon de donnees au complet');

```

% Graphe des données de test

```

x = newCoor(testIndex==1,1);
y = newCoor(testIndex==1,2);
patchSize = 80*max(prob_values,[],2);
colorTrueClassPlot = colorTrueClass(testIndex==1,:);
figure; hold on;
scatter(x,y,2*patchSize,colorTrueClassPlot,'o');

```

```
scatter(x,y,patchSize,colorResultClass,'o','filled');
```

```
% Graphe des données d'apprentissage
```

```
x = newCoor(trainIndex==1,1);
```

```
y = newCoor(trainIndex==1,2);
```

```
patchSize = 30;
```

```
colorTrueClassPlot = colorTrueClass(trainIndex==1,:);
```

```
scatter(x,y,patchSize,colorTrueClassPlot,'o');
```

```
title('Resultats de la classification');
```

LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES

- Aladin S., Tremblay C., (2018). « Cognitive Tool for Estimating the QoT of New Lightpaths ». Optical Fiber Communications Conference and Exhibition (OFC).
- Alpaydin E., (2010). « Introduction to Machine Learning ». (2nd éd) Cambridge, Massachusetts, The MIT Press, p. 489.
- Azodolmolky S., Perello J., Angelou M., Agraz F., Velasco L., Spadaro S., Pointurier Y., Francescon A., Saradhi C. V., Kokkinos P., Varvarigos E., Zahr S. A., Gagnaire M., Gunkel M., Klonidis D., Tomkos I., (2011). « Experimental Demonstration of an Impairment Aware Network Planning and Operation Tool for Transparent / Translucent Optical Networks ». Journal of Lightwave Technology, vol. 29, no 4, p. 439-448.
- Barletta L., Giusti A., Rottondi C., Tornatore M., (2017). « QoT Estimation for Unestablished Lightpaths using Machine Learning ». Optical Fiber Communications Conference and Exhibition (OFC).
- Breiman L., (2001). « Random Forests ». Machine Learning, 45(1) p. 5-32.
- Caballero A., Aguado J. C., Borkowski R., Saldana S., Jimenez T., Miguel I., Arlunno V., Duran R. J., Zibar D., Jensen J. B., Lorenzo R. M., Abril E. J., Monroy I. T., (2012). « Experimental Demonstration of a Cognitive Quality of Transmission Estimator for Optical Communication Systems ». Optical Society of America (OSA).
- Caballero A., Borkowski R., Zibar D., Monroy I. T., (2013). « Performance Monitoring Techniques Supporting Cognitive Optical Networking ». 15th International Conference on Transparent Optical Networks (ICTON).
- Caballero A., Borkowski R., Miguel I., Duran R. J., Aguado J. C., Fernandez N., Jimenez T., Rodriguez I., Sanchez D., Lorenzo R. M., Klonidis D., Palkopoulou E., Diamantopoulos N. P., Tomkos I., Siracusa D., Francescon A., Salvadori E., Ye Y., Vizcaino J. L., Pittala F., Tymecki A., Monroy I. T., (2014). « Cognitive, Heterogeneous and Reconfigurable Optical Networks: The CHRON Project ». Journal of Lightwave Technology, vol. 32, no 13, p. 2308-2323.
- Cortes C. et Vapnik V., (1995). « Support Vector Networks ». Machine Learning, vol. 20, no 3, p. 273-297.
- Carena A., Bosco G., Curri V., Jiang Y., Poggiolini P., Forghieri F., (2014). « EGN Model of Non-Linear Fiber Propagation ». Optics Express 22, p. 16335-16362.

- Chih-Chung Chang, Chih-Jen Lin, LIBSVM: a library for support vector machines. ACM Transactions on Intelligent Systems and Technology, 2:27:1--27:27, (2011). Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- Dar R., Feder M., Mecozzi A., Shtaif, (2013). « Properties of Nonlinear Noise in long, dispersion-uncompensated fiber links ». Optics Express 21, p. 25685-25699.
- Dar R., Feder M., Mecozzi A., Shtaif, (2014). « Accumulation of Nonlinear Interference Noise in Fiber-Optic Systems ». Optics Express 22, p. 14199-14211.
- Hranilovic S., Kschischang F. R., (2003). « Optical Intensity-Modulated Direct Detection Channels: Signal Space and Lattice Codes » IEEE Transactions on Information Theory vol. 49, no 6, p. 157-179.
- Isautier P., Pan J., Langston J., Ralph S. E., (2014). « Performance Comparison of Autonomous Software-Defined Coherent Optical Receivers » IEEE Photonics Conference (IPC), p. 148-149.
- Infinera Corporation (2016) « Coherent WDM Technologies » White paper
- Jiménez T, Aguado J. C., Miguel I., Duran R. J., Sanchez D., Angelou M., Merayo N., Fernandez P., Fernandez N., Lorenzo R. M., Rodriguez I., Tomkos I., Abril E. J., (2012). « Optimization of the Knowledge Base of a Cognitive Quality of Transmission Estimator for Core Optical Networks ». 16th International Conference on Optical Network Design and Modelling (ONMD).
- Jiménez T, Aguado J. C., Miguel I., Duran R. J., Angelou M., Merayo N., Fernandez P., Lorenzo R. M., Tomkos I., Abril E. J., (2013). « A Cognitive Quality of transmission Estimator for Core Optical Networks ». Journal of Lightwave Technology, vol. 31, no 6, p. 942-951.
- Kazuro Kikuchi, (2016). « Fundamentals of Coherent Optical Fiber Communications ». Journal of Lightwave Technology, vol. 34, no 1, p. 157-179.
- Khan F. N., Zhou Y., Lau A. P. T., Lu C., (2012) « Modulation Format Identification in Heterogeneous Fiber-Optic Networks using Artificial Neural Networks » IEEE Photonics Technology Letters, vol. 22, no. 22, p. 1665-1667
- Le Nguyen Binh, (2015). « Advanced Digital Optical Communications ». (2nd éd.) European Research Center, Huawei Technologies, Germany, p. 65
- Poggiolini Pierluigi (2012). « The GN Model of Non-Linear Propagation in Uncompensated Coherent Optical Systems ». Journal of Lightwave Technology, vol. 30, no 24, p. 3857-3879.

- Poggiolini P., (2013) « Analytical Modeling of Non-Linear Propagation in Coherent Systems ». Optical Fiber Communication Conference and Exposition and the National Fiber Optic Engineers Conference (OFC/NFOEC).
- Poggiolini P., Bosco G., Carena A., Curri V., Jiang Y., Forghieri F., (2014). « The GN-Model of Fiber Non-Linear Propagation and its Applications ». Journal of Lightwave Technology, vol. 32, no 4, p. 694-721.
- Ramaswami R., Sivarajan K. N., Sasaki G. H., (2010). « Optical Networks: A practical Perspective ». (3rd éd.) p. 10, San Francisco, CA, USA: Morgan Kaufmann.
- Rottondi C., Barletta L. Giusti A., Tornatore M., (2018). « Machine-Learning Method for Quality of Transmission Prediction of Unestablished Lightpaths » J. Opt. Commun. Netw./Vol. 10, No 2
- Shalev-Shwartz S., Ben-David S., (2014) « Understanding Machine Learning: From Theory to Algorithms ». Cambridge University Press.
- Tan M.C., Khan F. N., Al-Arashi W. H., Zhou Y., Lau A. P. T., (2014). « Simultaneous Optical Performance Monitoring and Modulation Format/Bit-rate Identification using Principal Component Analysis ». Journal of Optical Communications and Networking, vol. 6, no 1, p. 441-448.
- Thomas R., DaSilva L. A., MacKenzie A. B., (2005). « Cognitive Networks ». 1st IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks, p. 352-360.
- Thrane J., Wass J., Piels M., Diniz J. C. M., Jones R., Zibar D., (2017). « Machine Learning Techniques for Optical Performance Monitoring From Directly Detected PDM-QAM Signals ». Journal of Lightwave Technology, vol. 35, no 4, p. 868-875.
- Tremblay C., Aladin S. (2018). « Machine Learning Techniques for Estimating the Quality of Transmission of Lightpaths ». Institute of Electrical and Electronics Engineers Summer Topicals Meeting Series.
- Uwambajimana M. C., (2016). « Analyse comparative de performance de Systèmes de Transmission Optique à 100 Gbit par seconde ». Mémoire déposé à l'Ecole de Technologie Supérieure.
- Wolpert David. H., (1996). « The Lack of A Priori Distinctions between Learning Algorithms ». Neural Computation, p. 1341-1390
- Wolpert David H., Macready William G., (1997). « No Free Lunch Theorems for Optimization ». IEEE Transactions on Evolutionary Computation **1**, 67

Xiaogang Y., Wu J., Li Y., Li W., Hong X., Guo H., Zuo Y., Lin J., (2012) « Nonlinear Signal-Noise Interactions in Dispersion Managed Coherent PM-QPSK Systems in the presence of PMD ». Optics Express, vol. 20, no.25, p. 27596-27602