

Titre: Application du découpage de circuits quantiques pour la détection d'anomalies réseaux
Title:

Auteur: Hatim Lakhdar
Author:

Date: 2026

Type: Mémoire ou thèse / Dissertation or Thesis

Référence: Lakhdar, H. (2026). Application du découpage de circuits quantiques pour la détection d'anomalies réseaux [Mémoire de maîtrise, Polytechnique Montréal].
Citation: PolyPublie. <https://publications.polymtl.ca/73226/>

 **Document en libre accès dans PolyPublie**
Open Access document in PolyPublie

URL de PolyPublie: <https://publications.polymtl.ca/73226/>
PolyPublie URL:

Directeurs de recherche: Soumaya Cherkaoui
Advisors:

Programme: génie informatique
Program:

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

**Application du découpage de circuits quantiques pour la détection
d'anomalies réseaux**

HATIM LAKHDAR

Département de génie informatique et génie logiciel

Mémoire présenté en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*
Génie informatique

Février 2026

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

Ce mémoire intitulé :

**Application du découpage de circuits quantiques pour la détection
d'anomalies réseaux**

présenté par **Hatim LAKHDAR**

en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

a été dûment accepté par le jury d'examen constitué de :

Alejandro QUINTERO, président

Soumaya CHERKAOUI, membre et directrice de recherche

Heng LI, membre

REMERCIEMENTS

Je voudrais remercier Mon Dieu pour m'avoir permis d'être dans une université prestigieuse, de faire un projet pertinent, et de m'avoir donné la force de continuer malgré la difficulté. Ensuite je voudrais remercier mes parents car ils m'ont permis de vivre cette vie merveilleuse et parce qu'il m'ont éduqué et appris la valeur de la vie. Je remercie mes sœurs qui m'ont toujours soutenue et sans qui je n'aurais pas été l'homme stable que je suis maintenant. Je voudrais ensuite remercier mon encadrante Soumaya Cherkaoui car elle m'a ouvert les portes pour être dans cette université, elle a cru en moi malgré tous les échecs, et elle n'a jamais cessé de me soutenir

RÉSUMÉ

La décomposition de circuit est une technique qui permet de couper un circuit quantique dans le but de l'exécuter sur une machine avec moins de qubit que ce que le circuit original demande. Dans les modèles d'apprentissage machine quantique, les jeux de données doivent être encodés sous forme d'états quantiques pour être utilisés pour l'entraînement. Des jeux de données trop volumineux sont difficiles à utiliser car après l'encodage, ils donnent lieu à des circuits quantiques trop grands qui font que leur entraînement prend un temps exponentiel par rapport à leur dimension. Dans cette contribution on applique la décomposition de circuit dans un jeu de données volumineux pour pouvoir exécuter l'entraînement avec moins de qubits. Nous utiliserons dans la démonstration le dataset de détection d'attaque réseau UNSW-NB15, qu'on mettra en entrée d'un modèle de réseau neuronal quantique hybride constitué d'une couche quantique et d'une couche classique, nous montrerons à travers nos expériences que le découpage de circuit quantique peut être une alternative intéressante pour la réduction de données en comparant trois modèles de circuits coupés à un circuit normal avec encodage par amplitude, et un circuit normal avec données réduites par analyse en composantes principales.

ABSTRACT

Quantum circuit decomposition is a technique that enables partitioning a quantum circuit into smaller subcircuits to execute it on devices with fewer qubits than the original circuit requires. In quantum machine learning models, datasets must be encoded into quantum states before training, which often leads to large and complex circuits when the dataset is high-dimensional. These large circuits significantly increase the training time, which scales exponentially with circuit size. In this work, we apply circuit decomposition to large datasets to enable training with fewer qubits. Using the UNSW-NB15 network attack detection dataset as a case study, we design a hybrid quantum-classical neural network combining a quantum layer and a classical layer. Through our experiments, we demonstrate that quantum circuit cutting can serve as an effective alternative to classical data reduction methods by comparing the performance of three cut-based quantum models with a standard amplitude-encoded circuit and a PCA-reduced circuit.

TABLE DES MATIÈRES

REMERCIEMENTS	iii
RÉSUMÉ	iv
ABSTRACT	v
LISTE DES TABLEAUX	viii
LISTE DES FIGURES	ix
LISTE DES SIGLES ET ABRÉVIATIONS	x
CHAPITRE 1 INTRODUCTION	1
1.1 Éléments de la problématique	2
1.2 Objectifs de recherche	3
1.3 Contribution attendue	4
1.4 Structure du rapport	4
CHAPITRE 2 REVUE DE LITTÉRATURE	6
2.1 Circuit cutting	6
2.1.1 Principes généraux	6
2.1.2 Variantes algorithmiques	6
2.1.3 Problématique du placement des coupes	7
2.2 Apprentissage machine quantique pour la détection d'intrusions réseau	7
2.2.1 QSVM et méthodes basées noyaux	7
2.2.2 Circuits variationnels	7
2.2.3 HQNN et réseaux hybrides profonds	7
2.2.4 Modèles génératifs	8
2.2.5 Positionnement du présent travail	8
2.3 Synthèse et gap de la littérature	8
CHAPITRE 3 FONDEMENTS THÉORIQUES	9
3.1 Bases de l'informatique quantique	9
3.1.1 Qubits et espace de Hilbert	9
3.1.2 Mesure et distribution de probabilités	9
3.1.3 Portes quantiques et évolution unitaire	9
3.1.4 Intrication	9

3.1.5	Matrice de densité et décohérence	10
3.1.6	Circuits quantiques	10
3.2	Découpage de Circuit Quantique	10
3.2.1	Définition du problème et contraintes NISQ	10
3.2.2	Schéma de découpe par observables de Pauli	11
3.2.3	Coût théorique en fonction du nombre de coupes	11
3.2.4	Types de coupes et justification du choix	14
3.3	HQNN	15
3.4	Jeu de données UNSW-NB15	16
CHAPITRE 4 RÉSULTATS EXPÉRIMENTAUX ET ANALYSE		19
4.1	Méthodologie proposée	19
4.1.1	Prétraitement des données	19
4.1.2	Méthodologie HQNN	20
4.1.3	Modèles	21
4.2	Résultats	23
4.2.1	Métriques d'évaluation des modèles	24
4.2.2	Comportement à l'entraînement	25
4.2.3	Performances globales sur le test	27
4.2.4	Discussion des résultats	28
4.2.5	Analyse complémentaire	28
CHAPITRE 5 CONCLUSION		30
5.1	Récapitulatif du travail	30
5.2	Contributions principales	30
5.3	Limites du mémoire	30
5.4	Perspectives de recherche	30
5.5	Conclusion générale	31
RÉFÉRENCES		32

LISTE DES TABLEAUX

Tableau 3.1	Variables à faible impact dans le jeu de données UNSW-NB15.	17
Tableau 3.2	Top 5 des features les plus influentes du jeu de données UNSW-NB15.	18
Tableau 4.1	Résumé des modèles évalués : taille des sous-circuits, encodage et nombre de features utilisés.	22
Tableau 4.2	Détails expérimentaux des modèles quantiques	24
Tableau 4.3	Performances sur le jeu de test pour chaque modèle	28
Tableau 4.4	Meilleures métriques d’entraînement pour chaque modèle	28

LISTE DES FIGURES

Figure 3.1	Exemple de découpe sur un circuit à 4 qubits.	12
Figure 3.2	Circuit complet et ensemble des sous-circuits dérivés après découpage.	13
Figure 3.3	Exemple d'architecture HQNN	16
Figure 4.1	Répartition des données avant l'entraînement	20
Figure 4.2	Modèles évalués dans les expérimentations	23
Figure 4.3	Précision d'entraînement pour les cinq modèles	26
Figure 4.4	Perte d'entraînement pour les cinq modèles	26
Figure 4.5	AUC-PR d'entraînement pour les cinq modèles	27
Figure 4.6	Matrice de Confusion pour 24-6	29

LISTE DES SIGLES ET ABRÉVIATIONS

HQNN	Hybrid Quantum Neural Network
NISQ	Noisy Intermediate-Scale Quantum
QML	Quantum Machine Learning
PCA	Principal Component Analysis
SMT	Satisfiability Modulo Theories
QSVM	Quantum Support Vector Machine
QML-IDS	Quantum Machine Learning for Intrusion Detection Systems
QCNN	Quantum Convolutional Neural Network
CV-VQNN	Continuous-Variable Variational Quantum Neural Network

CHAPITRE 1 INTRODUCTION

Le calcul quantique est aujourd’hui l’un des domaines les plus prometteurs des sciences et technologies de l’information. En exploitant les propriétés de la mécanique quantique, il ouvre la possibilité de réaliser des calculs qu’un ordinateur classique mettrait un temps démesuré à effectuer [1, 2]. Depuis une dizaine d’années, l’informatique quantique a énormément évolué, elle est passée d’une science purement théorique à un domaine expérimentalement actif, particulièrement avec l’émergence de dispositifs NISQ (Noisy Intermediate-Scale Quantum) [3–5]. Cependant, en raison des contraintes du matériel NISQ, telles que le nombre limité de qubits, le bruit et les problèmes d’évolutivité dans la profondeur des circuits, les algorithmes d’apprentissage machine quantique restent difficilement praticables [6]. Pour pallier ces limites, plusieurs approches ont été proposées afin de rendre les circuits plus légers ou modulaires. Parmi elle les modèles de réseaux neuronaux quantiques hybrides (HQNN) [7, 8] qui sont apparus comme une alternative prometteuse, combinant des couches classiques et quantiques pour les tâches d’apprentissage automatique, ils exploitent les circuits quantiques pour les représentations complexes tout en conservant la robustesse classique, ce qui les rend adaptés au matériel de l’ère NISQ [9]. Malgré leur potentiel, les HQNN sont confrontés à des défis d’évolutivité en raison des limitations des qubits. Les circuits quantiques à grande échelle souffrent de bruit [10], de barren plateau [11], et une charge de calcul importante. Le découpage de circuits quantiques [12] est une technique qui partitionne les grands circuits en sous-circuits plus petits, permettant ainsi leur exécution sur des dispositifs à qubits limités. Dans le contexte de l’apprentissage machine, cette approche présente un intérêt particulier. En effet, l’encodage de données classiques sous forme d’états quantiques [13] génère souvent des circuits très profonds et coûteux à exécuter. L’idée de découper ces circuits permet théoriquement de contourner les limitations matérielles. Le présent rapport s’inscrit dans cette démarche. Il propose d’appliquer la décomposition de circuits quantiques à un cas concret : la détection d’attaques réseau à l’aide du jeu de données *UNSW-NB15* [14]. Le modèle étudié repose sur une architecture hybride, combinant une couche quantique paramétrée et une couche classique. À travers cette étude, nous cherchons à montrer que le découpage de circuits peut constituer une alternative crédible à la réduction de dimension classique, tout en ouvrant la voie à de nouvelles stratégies d’optimisation dans les modèles quantiques hybrides.

1.1 Éléments de la problématique

Dans le domaine de l'apprentissage machine quantique, les modèles QML nécessitent souvent de manipuler des jeux de données de grande dimension, notamment dans les domaines de la vision, de la cybersécurité ou de la détection d'anomalies [15]. Pour être utilisés par un modèle quantique, ces jeux de données doivent être encodés en états quantiques. Un dataset avec de nombreuses caractéristiques peut rapidement conduire à des circuits trop grands pour les machines actuelles. Plusieurs approches ont été proposées pour contourner ce problème. L'une d'entre elles consiste à réduire la dimension du jeu de données avant l'encodage, par des méthodes classiques comme PCA [16] ou les autoencodeurs [17]. Ces techniques permettent de diminuer le nombre de variables d'entrée tout en conservant une partie de l'information utile. Cependant, elles restent limitées par leur nature classique et peuvent modifier la structure des données d'origine, en supprimant des corrélations utiles pour la tâche d'apprentissage.

Un second axe concerne la réduction de la complexité des circuits quantiques. Cette approche ne modifie pas les données, mais cherche à adapter l'architecture du circuit pour faciliter son exécution.

C'est dans ce contexte que la décomposition de circuits quantiques apparaît comme une option intéressante. Plutôt que de réduire les données avant leur entrée dans le modèle, cette méthode propose de découper le circuit en plusieurs sous-circuits plus petits. Chaque sous-circuit peut être exécuté indépendamment sur une machine disposant de moins de qubits, puis les résultats sont recombinaés pour reconstituer la sortie globale. Malgré son intérêt, la décomposition de circuits dans un contexte d'apprentissage quantique reste encore peu étudiée. Les travaux existants se concentrent surtout sur la faisabilité et les méthodes de recombinaison des résultats.

Ces éléments conduisent à distinguer deux axes : (i) la réduction de dimension des données avant l'encodage, et (ii) la réduction de la complexité des circuits par décomposition. Ce mémoire s'intéresse principalement au second axe.

Le présent travail étudie l'application de la décomposition de circuits à un problème de détection d'attaques réseau à l'aide du dataset *UNSW-NB15*. L'objectif est d'évaluer dans quelle mesure cette approche peut réduire la complexité d'un modèle hybride. Le choix de ce jeu de données se justifie par sa taille et sa structure multi-classe, qui permettent de tester le comportement de circuits découpés.

La problématique associée peut être formulée de la manière suivante :

1. Comment exécuter des modèles d'apprentissage quantique sur des machines disposant

- d'un nombre limité de qubits ?
2. Dans quelle mesure la décomposition de circuits permet-elle de réduire la complexité d'un modèle sans perte importante de performance ?
 3. La décomposition peut-elle jouer un rôle similaire à une réduction de données dans un modèle hybride quantique-classique ?
 4. La décomposition de circuits est-elle efficace sur un jeu de données réseau réel sans altérer les corrélations utiles ?

1.2 Objectifs de recherche

L'objectif principal de ce travail est d'évaluer la faisabilité et l'intérêt de la décomposition de circuits quantiques pour l'exécution de modèles hybrides quantiques-classiques dans un contexte de ressources limitées. Un second objectif principal est de comparer les performances de cette approche à celles obtenues avec des méthodes classiques de réduction de dimension, telles que PCA.

Pour atteindre ces objectifs, plusieurs objectifs spécifiques ont été définis :

- **Intégrer la décomposition dans un modèle d'apprentissage hybride** : concevoir un réseau quantique-classique combinant une couche quantique paramétrée et une couche dense classique, en introduisant des mécanismes de découpe adaptés.
- **Évaluer l'impact de la découpe sur les performances du modèle** : comparer les résultats des circuits découpés à ceux de circuits non découpés, sur la base d'indicateurs tels que la précision, la perte d'entraînement et la stabilité des gradients.
- **Analyser les performances à l'aide de métriques avancées** : compléter l'évaluation par des indicateurs tels que le Matthews Correlation Coefficient (MCC) et l'Area Under the Precision-Recall Curve (AUC-PR), afin d'obtenir une analyse plus complète.
- **Comparer la décomposition à une réduction de dimension classique** : confronter les performances des modèles découpés à celles obtenues avec un prétraitement des données classiques, afin d'identifier les avantages et les limites de chaque approche.
- **Appliquer la méthode à un cas d'étude réel** : utiliser le dataset *UNSW-NB15* pour valider expérimentalement l'approche proposée dans un contexte de détection d'attaques réseau.

1.3 Contribution attendue

Ce travail vise à apporter une contribution à la fois méthodologique et expérimentale à l'application de la décomposition de circuits quantiques pour la détection d'attaques dans un jeu de données réseau. La littérature récente s'est principalement concentrée sur les aspects théoriques du circuit cutting, et les contributions applicatives n'ont pas encore étudié son intégration dans un modèle complet d'apprentissage hybride utilisant des données réelles.

La contribution attendue de cette recherche s'articule autour de trois axes principaux :

1. **Adaptation du circuit cutting à un contexte d'apprentissage supervisé :** développement d'un protocole permettant d'appliquer la décomposition de circuits à des modèles quantiques paramétrés tout en conservant la cohérence de l'apprentissage global. Ce protocole inclura les étapes nécessaires pour tester le circuit cutting sur le dataset *UNSW-NB15*, depuis la configuration des sous-circuits jusqu'à la recombinaison des sorties.
2. **Évaluation comparative entre découpe et réduction classique de données :** mise en place d'une analyse expérimentale comparant plusieurs configurations : un modèle quantique complet avec encodage par amplitude, des modèles découpés selon différentes topologies, et un modèle utilisant une réduction de dimension par PCA. La comparaison portera de manière systématique sur plusieurs topologies découpées (24-4, 24-6, 24-8) et deux modèles non découpés (Amplitude et PCA).
3. **Démonstration sur un jeu de données réel :** application de la méthode au dataset *UNSW-NB15*. Cette étude de cas permettra d'évaluer dans quelles conditions la décomposition de circuits peut être utilisée comme solution à la contrainte matérielle liée au nombre de qubits et comme alternative à des approches classiques de prétraitement.

1.4 Structure du rapport

Le présent rapport est structuré comme suit :

- **Chapitre 1 — Introduction :** présentation du contexte, de la problématique, des objectifs et des contributions du travail.
- **Chapitre 2 — Revue de littérature :** synthèse des travaux liés aux modèles hybrides quantiques-classiques et aux méthodes de décomposition de circuits.
- **Chapitre 3 — Fondements théoriques :** rappel des notions essentielles en calcul quantique, en apprentissage hybride et en décomposition de circuits.
- **Chapitre 4 — Résultats expérimentaux et analyse :** présentation et compa-

raison des performances obtenues pour différentes topologies découpées et modèles de référence.

- **Chapitre 5 — Discussion et conclusion** : discussion des résultats, limites identifiées et perspectives de recherche.

CHAPITRE 2 REVUE DE LITTÉRATURE

2.1 Circuit cutting

2.1.1 Principes généraux

La décomposition de circuits quantiques est devenue une approche prometteuse pour exécuter des circuits de grande taille sur des processeurs quantiques limités en nombre de qubits. Le travail fondateur de [12] a introduit une stratégie générale de découpe fondée sur la partition du graphe du circuit en (K,d) -clusters. L'idée consiste à regrouper les portes en fragments manipulables localement par un processeur de taille d , puis à reconnecter ces fragments par recombinaison statistique. Cette méthode permet de contourner la contrainte matérielle imposée par la faible connectivité et le nombre réduit de qubits physiques. Toutefois, le coût computationnel de recombinaison croît exponentiellement avec le nombre de coupes K , ce qui limite l'approche lorsque le circuit est fortement intriqué. Ces limites motivent le développement de variantes visant à réduire le coût de reconstruction ou à mieux structurer la découpe.

2.1.2 Variantes algorithmiques

L'approche CutQC introduite par [18] améliore la procédure initiale en exploitant une orchestration hybride permettant d'automatiser la création des sous-circuits, d'optimiser la génération des fragments et de paralléliser l'exécution. Cette méthode a montré qu'un découpage plus important peut rendre simulables des circuits auparavant hors de portée.

D'autres approches cherchent à diminuer le coût de la reconstruction classique. [19] proposent un protocole fondé sur les mesures randomisées permettant de réduire le nombre d'échantillons nécessaires pour reconstruire des observables globales. [20] introduisent une technique utilisant des échanges d'informations classiques entre fragments afin d'alléger certaines étapes de recombinaison. Plus récemment, [21] étudient l'usage d'états partiellement intriqués pour contrôler l'erreur induite par la coupure.

Une autre famille de méthodes repose sur le wire cut, introduit par [22]. Cette approche consiste à couper explicitement une ligne du circuit et à remplacer l'information quantique manquante par un schéma mesure-injection. Elle permet une découpe locale, mais au prix d'un nombre élevé de mesures et d'un coût de reconstruction plus important.

2.1.3 Problématique du placement des coupes

Le placement optimal des coupes constitue un problème central dans ce domaine. Plusieurs travaux le formulent comme une tâche d’optimisation combinatoire. [23] utilisent des solveurs SMT (Satisfiability Modulo Theories) pour déterminer automatiquement les zones à découper en minimisant le coût associé. D’autres travaux s’appuient sur le partitionnement d’hypergraphes pour modéliser les dépendances logiques du circuit. Les approches de [24] et [25] exploitent des heuristiques spatio-temporelles afin d’identifier des coupes préservant la structure computationnelle tout en réduisant le nombre de fragments. Ces travaux montrent que la question du placement des coupes reste un défi méthodologique important pour rendre le circuit cutting plus efficace.

2.2 Apprentissage machine quantique pour la détection d’intrusions réseau

2.2.1 QSVM et méthodes basées noyaux

Plusieurs modèles hybrides ont été appliqués à la détection d’intrusions sur réseaux, notamment via le dataset UNSW-NB15 [14]. [26] proposent une combinaison autoencodeur classique + QSVM (Quantum Support Vector Machine) quantique, obtenant une précision d’environ 0.75. Ce type de modèle repose sur l’idée que les frontières de décision quantiques peuvent exploiter des espaces de représentation non linéaires.

2.2.2 Circuits variationnels

Les circuits variationnels sont largement étudiés en QML-IDS (Quantum Machine Learning for Intrusion Detection Systems). [27] montrent que l’encodage par amplitude peut extraire davantage d’information structurelle et qu’un modèle hybride variationnel atteint des performances compétitives. Dans [28], les auteurs introduisent un réseau variationnel inspiré des architectures convolutionnelles et rapportent une précision de 94.51% sur UNSW-NB15.

2.2.3 HQNN et réseaux hybrides profonds

[29] montrent qu’il est possible d’entraîner des réseaux neuronaux hybrides à grande échelle en utilisant le circuit cutting pour contourner la limitation en qubits. Ce travail s’intéresse à des HQNN appliqués aux jeux de données MNIST et Digits. [30] proposent une architecture réunissant QSVM, circuits variationnels et QCNN (Quantum Convolutional Neural Network), atteignant des scores F1 proches de 90%.

2.2.4 Modèles génératifs

Les modèles génératifs quantiques sont également explorés. [31] utilisent des autoencodeurs et générateurs quantiques appliqués à UNSW-NB15, obtenant une AUC proche de 0.792. [32] introduisent une architecture hybride continue-discrète CV-VQNN (Continuous-Variable Variational Quantum Neural Network) qui montre des performances supérieures à plusieurs modèles classiques.

2.2.5 Positionnement du présent travail

Malgré la variété des modèles d'apprentissage machine quantique appliqués à la cybersécurité, très peu de travaux intègrent explicitement le circuit cutting dans une architecture HQNN complète appliquée au dataset UNSW-NB15. Ce point constitue l'un des manques identifiés dans la littérature et motive l'approche développée dans ce mémoire.

2.3 Synthèse et gap de la littérature

La littérature actuelle propose de nombreuses méthodes de circuit cutting, des variantes algorithmiques et des approches d'optimisation du placement des coupes. Elle offre également un panorama riche de modèles quantiques appliqués à la détection d'intrusions, incluant QSVM, circuits variationnels, HQNN et modèles génératifs.

Cependant, aucune contribution ne combine l'usage du circuit cutting avec une architecture HQNN complète dans le cadre d'un IDS appliqué à un dataset réel comme UNSW-NB15.

Le présent mémoire vise à combler ce manque en proposant une étude expérimentale intégrant le circuit cutting dans un modèle HQNN et en analysant ses performances sur UNSW-NB15.

CHAPITRE 3 FONDEMENTS THÉORIQUES

3.1 Bases de l'informatique quantique

3.1.1 Qubits et espace de Hilbert

L'unité fondamentale de l'information quantique est le *qubit* ou bit quantique. Contrairement au bit classique, un qubit peut exister dans une superposition linéaire des états $|0\rangle$ et $|1\rangle$:

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle, \quad |\alpha|^2 + |\beta|^2 = 1.$$

Un système de n qubits vit dans un espace de Hilbert de dimension 2^n .

3.1.2 Mesure et distribution de probabilités

La mesure projette un état quantique sur l'un des états de la base choisie, en général la base computationnelle. Pour un état

$$|\psi\rangle = \sum_{y \in \{0,1\}^n} \alpha_y |y\rangle,$$

la probabilité d'obtenir $|y\rangle$ est donnée par $|\alpha_y|^2$.

3.1.3 Portes quantiques et évolution unitaire

L'évolution d'un système quantique est décrite par des opérateurs unitaires. Les portes quantiques usuelles incluent :

- **Hadamard** : crée une superposition équilibrée.
- **CNOT** : introduit une corrélation entre deux qubits.
- **Portes de rotation** : permettent de paramétrer l'état d'un qubit au sein des circuits variationnels.

3.1.4 Intrication

Un état quantique est intriqué lorsqu'il ne peut pas s'écrire comme un produit tensoriel d'états individuels. Par exemple :

$$|\Phi^+\rangle = \frac{|00\rangle + |11\rangle}{\sqrt{2}}.$$

3.1.5 Matrice de densité et décohérence

La matrice de densité permet de décrire les états purs et mixtes :

$$\rho = \sum_i p_i |\psi_i\rangle \langle \psi_i|.$$

La trace partielle permet de modéliser la perte d'information sur un sous-système, ce qui est utile pour analyser l'effet du bruit ou de la mesure dans les circuits découpés.

La décohérence correspond à la perte progressive des effets quantiques due à l'environnement. Elle transforme un état superposé en un état mixte, ce qui limite la durée de vie des calculs quantiques.

3.1.6 Circuits quantiques

Un circuit quantique est une composition ordonnée de portes unitaires et, éventuellement, de mesures. Il réalise une transformation globale :

$$|\psi_{\text{final}}\rangle = U_k \cdots U_2 U_1 |\psi_{\text{initial}}\rangle.$$

La profondeur du circuit (nombre de couches) et sa largeur (nombre de qubits) conditionnent sa faisabilité sur les machines actuelles.

Les circuits paramétrés, utilisés dans les modèles variationnels, intègrent des portes dépendant de paramètres optimisés durant l'apprentissage.

3.2 Découpage de Circuit Quantique

3.2.1 Définition du problème et contraintes NISQ

Le découpage de circuit consiste à diviser un circuit quantique en sous-circuits plus petits, exécutés séparément, puis à recomposer leurs résultats pour retrouver le comportement du circuit complet. Cette approche est particulièrement adaptée aux processeurs quantiques de type NISQ, qui ne peuvent exécuter que des circuits de profondeur limitée avec un nombre restreint de qubits. Ces contraintes rendent difficile l'évaluation de modèles quantiques plus complexes ou d'architectures hybrides de grande taille.

3.2.2 Schéma de découpe par observables de Pauli

La méthode de découpe par observables de Pauli s'appuie sur la décomposition d'un état quantique dans la base des matrices de Pauli. Cette représentation permet d'isoler, pour chaque fil coupé, une mesure effectuée dans le premier sous-circuit et une préparation d'état correspondante dans le second. Les résultats des fragments sont ensuite recombinaés classiquement.

Décomposition de la matrice densité. Tout état d'un qubit, décrit par une matrice densité ρ , peut être écrit comme une combinaison linéaire des matrices de Pauli :

$$\rho = \frac{1}{2} \sum_{i=0}^3 c_i O_i, \quad O_i \in \{I, X, Y, Z\}, \quad (3.1)$$

où les coefficients $c_i = \text{Tr}(\rho O_i)$ sont réels et représentent les valeurs moyennes des observables correspondantes.

Chaque observable possède deux états propres $\rho_i^{(+)}$ et $\rho_i^{(-)}$. Par exemple :

$$\begin{aligned} Z &: |0\rangle, |1\rangle, \\ X &: |\pm\rangle = \frac{1}{\sqrt{2}}(|0\rangle \pm |1\rangle), \\ Y &: |\pm i\rangle = \frac{1}{\sqrt{2}}(|0\rangle \pm i|1\rangle). \end{aligned}$$

Mesure-préparation. Pour reconnecter un fil coupé, chaque terme de la décomposition est traité séparément :

1. la mesure de l'observable O_i dans le premier fragment C_u fournit l'espérance $\text{Tr}(\rho O_i)$;
2. le second fragment C_v est initialisé dans l'état propre correspondant, soit $\rho_i^{(+)}$, soit $\rho_i^{(-)}$.

Les contributions de toutes les paires $(O_i, \rho_i^{(\pm)})$ sont ensuite sommées afin de reconstruire l'espérance globale d'une observable sur le circuit complet :

$$\langle M \rangle = \sum_{i=0}^3 c_i \langle O_i \rangle_{C_u} \langle M \rangle_{C_v(\rho_i^{(\pm)})}. \quad (3.2)$$

3.2.3 Coût théorique en fonction du nombre de coupes

Le principal inconvénient de ce schéma de découpe est son coût exponentiel. Une coupe introduit jusqu'à 4 observables, et pour chacune deux états propres, soit jusqu'à 8 branches à

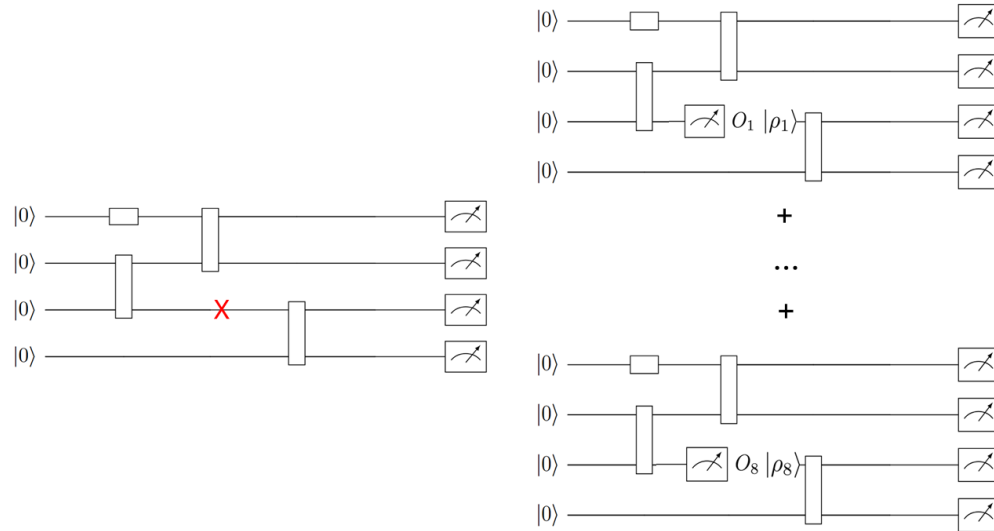
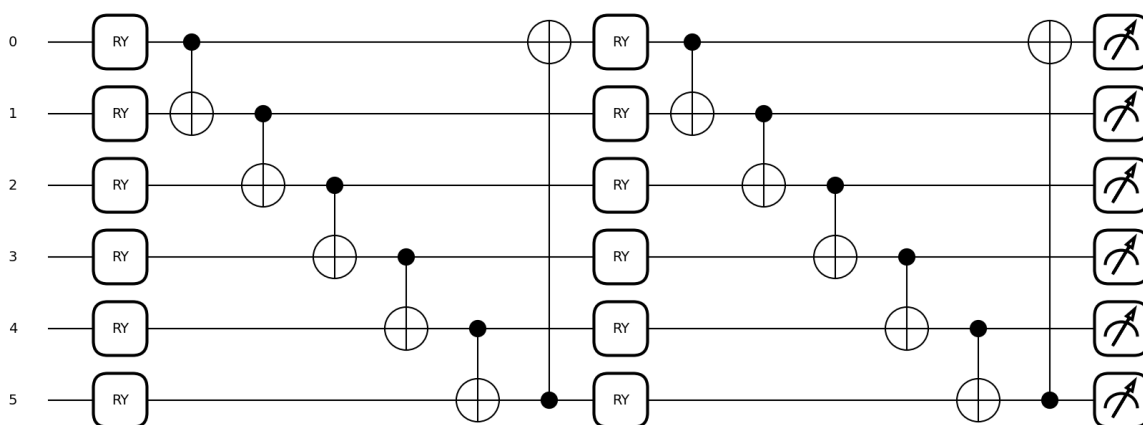
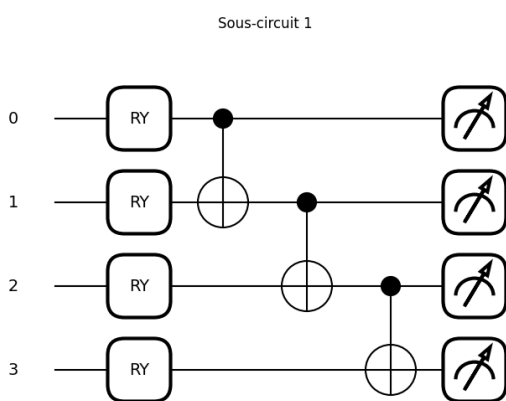


FIGURE 3.1 Exemple de découpe sur un circuit à 4 qubits.

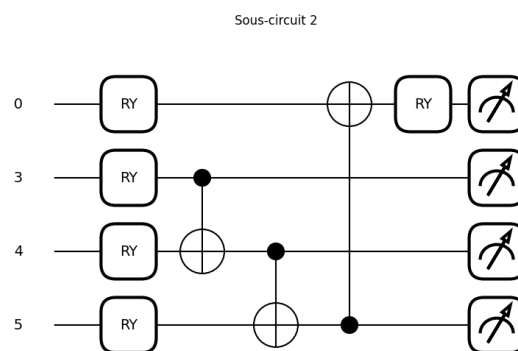
évaluer. En pratique, la recomposition peut être vue comme la somme pondérée des contributions de l'ensemble de ces branches, ce qui multiplie le nombre d'exécutions nécessaires des sous-circuits. Pour k coupes, on obtient ainsi au plus 16^k configurations. Ce facteur de croissance impose de limiter le nombre de coupes dans les applications pratiques, tout en exploitant le découpage pour dépasser la taille native des dispositifs NISQ.



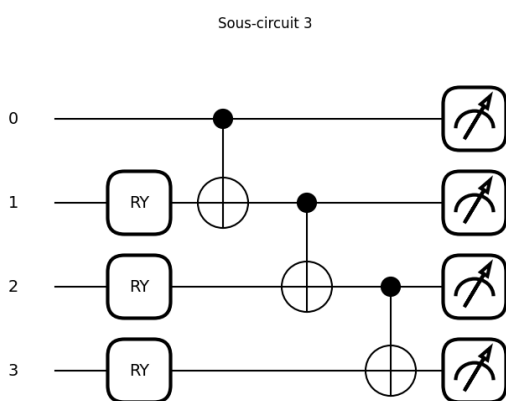
(a) Circuit quantique complet



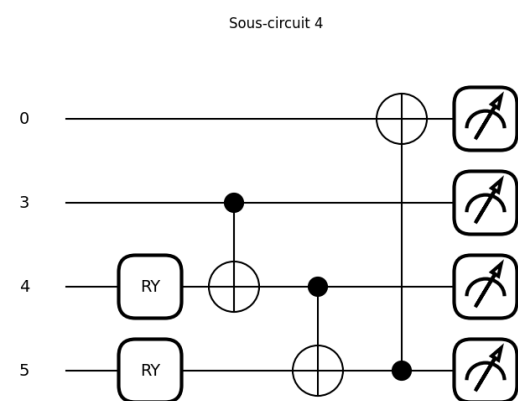
(b) Sous-circuit 1



(c) Sous-circuit 2



(d) Sous-circuit 3



(e) Sous-circuit 4

FIGURE 3.2 Circuit complet et ensemble des sous-circuits d eriv es apr es d ecoupage.

3.2.4 Types de coupes et justification du choix

Plusieurs stratégies de découpage peuvent être envisagées selon la structure du circuit et les contraintes matérielles.

Coupe de portes (Gate Cut) La coupe de porte consiste à décomposer une porte multi-qubits reliant deux sous-ensembles distincts en une combinaison linéaire d’opérateurs locaux. Cette méthode permet d’isoler une interaction spécifique sans sectionner directement un fil quantique. Elle est particulièrement adaptée lorsque les dépendances inter-fragments sont limitées à un nombre restreint de portes. Toutefois, la décomposition introduit également un surcoût exponentiel lors de la phase de recombinaison.

Coupe de fils (Wire Cut) La coupe de fil consiste à sectionner une ligne de qubit entre deux sous-circuits. La continuité de l’information est alors reconstruite via un schéma mesure-préparation basé sur la décomposition dans la base des observables de Pauli. Cette approche permet une séparation structurelle claire du circuit en fragments indépendants et offre un contrôle direct sur le nombre maximal de qubits par sous-circuit.

Approches hybrides Certaines méthodes combinent coupes de portes et coupes de fils afin d’optimiser simultanément la taille des fragments et le nombre total de coupes. Ces approches nécessitent généralement des techniques d’optimisation combinatoire telles que la programmation SMT ou le partitionnement d’hypergraphes.

Justification du choix. Dans le cadre de ce travail, la coupe de fil a été retenue pour plusieurs raisons. Premièrement, l’objectif principal était de réduire le nombre de qubits simultanément utilisés afin de rendre l’architecture compatible avec des dispositifs NISQ à capacité limitée. Deuxièmement, les architectures HQNN étudiées présentent une structure modulaire, ce qui permet une séparation naturelle en blocs via des coupes de fils. Troisièmement, la contrainte expérimentale imposait un nombre maximal de qubits par fragment (par exemple six qubits), contrainte plus facilement contrôlable avec une coupe de fil qu’avec une décomposition locale de portes. Enfin, la méthode mesure-préparation fondée sur la décomposition de Pauli offre un cadre théorique bien établi et directement implémentable dans une simulation hybride classique-quantique.

3.3 HQNN

Un HQNN est une architecture hybride qui combine un module quantique paramétré et une couche classique d'optimisation. Le principe central est une boucle hybride où l'encodage des données, l'évolution quantique, la mesure et la mise à jour classique des paramètres interagissent à chaque itération.

Un HQNN se compose principalement de deux sous-systèmes :

- Une couche quantique représentée par un circuit paramétré $U(\boldsymbol{\theta})$, appliqué à un registre de n qubits initialisés dans l'état $|0\rangle^{\otimes n}$.
- Une couche classique chargée de la fonction de coût et de l'optimisation des paramètres $\boldsymbol{\theta}$.

Boucle hybride d'apprentissage

Pour un ensemble d'échantillons $\{(\mathbf{x}_i, y_i)\}_{i=1}^N$, l'encodage quantique est effectué via un opérateur $U_{\text{enc}}(\mathbf{x}_i)$:

$$|\psi(\mathbf{x}_i)\rangle = U_{\text{enc}}(\mathbf{x}_i) |0\rangle^{\otimes n}.$$

Le circuit paramétré applique ensuite son évolution :

$$|\psi_{\boldsymbol{\theta}}(\mathbf{x}_i)\rangle = U(\boldsymbol{\theta}) |\psi(\mathbf{x}_i)\rangle.$$

La sortie quantique est donnée par la mesure d'une observable \hat{O} :

$$f_{\boldsymbol{\theta}}(\mathbf{x}_i) = \langle \psi_{\boldsymbol{\theta}}(\mathbf{x}_i) | \hat{O} | \psi_{\boldsymbol{\theta}}(\mathbf{x}_i) \rangle.$$

Cette sortie est transmise à une couche classique produisant une prédiction \hat{y}_i . La fonction de coût est alors définie par :

$$\mathcal{L}(\boldsymbol{\theta}) = \frac{1}{N} \sum_{i=1}^N \ell(\hat{y}_i, y_i),$$

et les paramètres sont mis à jour selon :

$$\boldsymbol{\theta}^{(t+1)} = \boldsymbol{\theta}^{(t)} - \eta \nabla_{\boldsymbol{\theta}} \mathcal{L}(\boldsymbol{\theta}^{(t)}).$$

Cette boucle constitue la structure de base utilisée pour toutes les architectures hybrides étudiées dans ce mémoire. Ces principes seront instanciés dans trois architectures découpées et deux architectures de référence, présentées et évaluées dans le Chapitre 4.

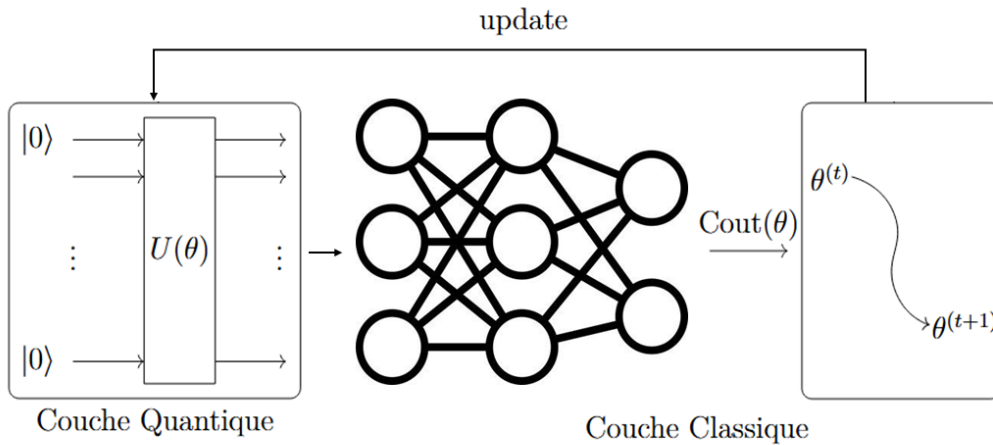


FIGURE 3.3 Exemple d'architecture HQNN

3.4 Jeu de données UNSW-NB15

Le jeu de données *UNSW-NB15* [14] a été conçu pour la recherche en détection d'intrusion réseau. Il contient 45 variables décrivant différents aspects des connexions réseau, incluant des statistiques au niveau des paquets, des informations de protocole et des caractéristiques comportementales du trafic. Parmi ces *variables*, les plus impactantes sont celles qui traduisent la dynamique et l'intensité des flux de communication, telles que `dur`, `sbytes`, `dbytes`, `spkts`, `dpkts`, ainsi que les variables temporelles `tcprtt`, `synack` et `ackdat`. Ces attributs constituent des indicateurs de comportements anormaux, car ils révèlent des différences notables dans les volumes, durées et temporalité entre trafic normal et trafic malveillant.

Un point important du jeu de données est le déséquilibre marqué entre certaines classes d'attaques et le trafic normal, ce qui influence fortement la qualité de l'apprentissage. Les classes les moins représentées (par exemple les attaques de type *Verre* ou *Shellcode*) apparaissent en faible quantité, tandis que d'autres catégories comme *Generic* dominent largement le jeu de données. Ce déséquilibre impose une sélection attentive des caractéristiques afin d'éviter que le modèle apprenne uniquement les comportements majoritaires.

Les *variables* de comptage contextuel telles que `ct_srv_src`, `ct_dst_ltm` et `ct_dst_src_ltm` présentent également une grande importance, puisqu'elles quantifient la fréquence et la ré-

currence de connexions spécifiques. Ces comportements sont typiques d'activités comme le *scanne* ou les attaques par déni de service.

À l'inverse, certaines variables identifiées dans le Tableau 3.1 présentent un impact faible. Elles possèdent une variance très limitée, une forte corrélation avec d'autres variables ou un caractère trop spécifique à un protocole donné. Pour ces raisons, elles ont été retirées afin de construire un ensemble de 24 caractéristiques plus informatives et mieux adaptées à la détection d'intrusions dans un contexte déséquilibré. Cette sélection permet au modèle quantique de se concentrer sur les variables réellement impactantes, ce qui est essentiel lorsqu'un circuit est contraint en nombre de qubits.

Variable	Raison du faible impact
proto	Très faible diversité (principalement TCP/UDP/ICMP) → faible variance.
service	Fortement corrélée avec proto et state .
state	Presque constante dans plusieurs sous-ensembles.
rate	Redondante avec les statistiques de charge.
sttl, dttl	TTL constant par protocole.
sload, dload	Corrélées avec sbytes/dbytes .
sloss, dloss	Presque toujours nulles.
sjit, djit	Corrélées avec sinpkt/dinpkt .
smean, dmean	Redondantes avec les volumes d'octets et de paquets.
ct_state_ttl	Faible variance.
is_ftp_login	Presque toujours 0.
ct_ftp_cmd	Très peu de flux FTP.
ct_flw_http_mthd	Spécifique au trafic HTTP.
ct_src_ltm	Corrélée avec ct_srv_src .
is_sm_ips_ports	Presque toujours nulle.
attack_cat	Variable cible.
label	Étiquette de classification.

TABLEAU 3.1 Variables à faible impact dans le jeu de données UNSW-NB15.

Pour le modèle utilisant PCA, seules 5 caractéristiques ont été conservées afin de réduire la dimension d'entrée tout en préservant les attributs considérés comme les plus impactants dans la littérature. Le choix de ces 5 variables s'appuie sur l'étude originale de [33], qui identifie les variables les plus efficaces pour séparer les comportements malveillants du trafic normal.

Variables	Raison du fort impact
sbytes	Indicateur clé d'un trafic anormal ou d'une exfiltration.
sload	Débit source révélant les comportements DoS.
sttl	Signale des paquets usurpés ou forgés.
ct_dst_src_ltm	Mesure la persistance des connexions.
sinpkt	Distingue activités automatisées et trafic normal.

TABLEAU 3.2 Top 5 des features les plus influentes du jeu de données UNSW-NB15.

CHAPITRE 4 RÉSULTATS EXPÉRIMENTAUX ET ANALYSE

4.1 Méthodologie proposée

4.1.1 Prétraitement des données

Le jeu de données *UNSW-NB15* contient différents types de trafic réseau, répartis en dix catégories représentant des comportements normaux et plusieurs formes d'attaques. Afin d'adapter le volume de données au cadre expérimental du modèle hybride quantique-classique, un échantillon équilibré de **2000 entrées** a été extrait.

Échantillonnage L'échantillon sélectionné comprend :

- **1000 entrées normales**, représentant la moitié de l'échantillon ;
- **1000 entrées d'attaque**, réparties équitablement entre les neuf catégories d'attaques.

Division entraînement / test L'ensemble des 2000 échantillons est ensuite divisé en :

- 1400 entrées pour l'entraînement (70%) ;
- 600 entrées pour le test (30%).

Ce protocole repose sur une seule séparation 70/30. Les expériences pourraient toutefois être étendues à des schémas multi-séparations (par exemple plusieurs séparations aléatoires ou validation croisée) afin de mieux évaluer la stabilité du modèle.

Nettoyage et préparation des variables Avant l'encodage quantique :

- les attributs non pertinents ou redondants sont supprimés ;
- les valeurs numériques sont normalisées ;
- les labels sont rendus binaires pour la classification.

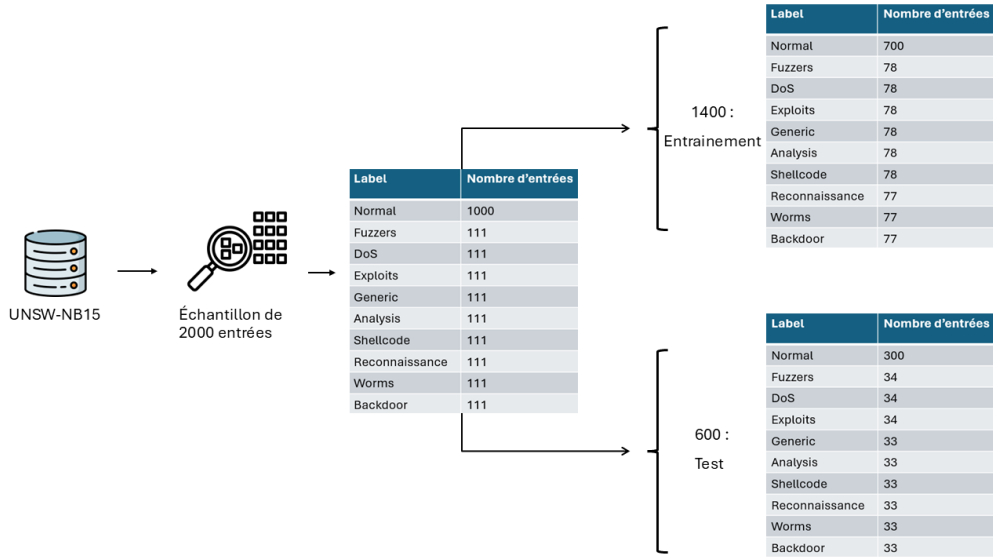


FIGURE 4.1 Répartition des données avant l'entraînement

4.1.2 Méthodologie HQNN

Dans cette partie, on détaille la méthodologie pour un circuit découpé en sous-circuits de 6 qubits. L'objectif est de classer une entrée classique $x \in \mathbb{R}^{24}$ (correspondant aux variables sélectionnées).

1 — Normalisation Chaque échantillon x est normalisé :

$$\tilde{x} = \frac{x - \mu(x)}{\sigma(x) + \varepsilon}.$$

2 — Encodage quantique

$$|\psi_{\text{enc}}^{(k)}\rangle = \bigotimes_{i=1}^{24} R_y(x_i^{(k)}) |0\rangle.$$

3 — Circuit paramétré dans chaque bloc

$$|\psi_{\text{out}}^{(k)}\rangle = U^{(k)}(\theta^{(k)})|\psi_{\text{enc}}^{(k)}\rangle.$$

4 — Découpage et recomposition du circuit Le circuit complet de 24 qubits est divisé en **4 sous-circuits de 6 qubits**. Chaque découpe introduit une frontière où l'information quantique est remplacée par un schéma mesure-préparation : le premier fragment mesure les observables associées au fil coupé, tandis que le second fragment est initialisé dans l'état

propre correspondant. La recombinaison finale repose sur une combinaison pondérée des sorties provenant de toutes les branches générées par les observables mesurées. Il s’agit d’une recombinaison statistique, similaire à la décomposition de Pauli, et impliquant plusieurs évaluations des fragments pour estimer la sortie globale.

5 — Mesure Chaque bloc produit un vecteur de mesures en base Z :

$$z_i^{(k)} = \langle \psi_{\text{out}}^{(k)} | Z_i | \psi_{\text{out}}^{(k)} \rangle.$$

6 — Reconstruction de la représentation globale

$$z = [z^{(1)}, z^{(2)}, z^{(3)}, z^{(4)}] \in \mathbb{R}^{24}.$$

7 — Couche neuronale classique

$$h_1 = \text{ReLU}(W_1 z + b_1), \quad h_2 = \text{ReLU}(W_2 h_1 + b_2), \quad \hat{y} = \sigma(W_3 h_2 + b_3).$$

8 — Apprentissage hybride de bout en bout La fonction de coût est :

$$\mathcal{L} = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})].$$

Les gradients quantiques sont obtenus par la parametric shift rule, les gradients classiques par rétropropagation, et l’optimisation se fait par Adam.

4.1.3 Modèles

Pour rendre le modèle précédent exécutable sur des dispositifs quantiques de taille réduite, cinq architectures ont été construites. Chaque modèle applique un schéma d’encodage et une découpe différente, permettant d’étudier l’impact du nombre de qubits et du découpage sur les performances globales.

Modèle Cut-4 (24–4). Dans ce modèle, le circuit global de 24 qubits est découpé en 6 sous-circuits de 4 qubits. Chaque fragment traite un groupe local de 4 caractéristiques, applique un petit circuit variationnel, puis transmet ses résultats à la couche classique après recombinaison statistique.

Modèle Cut-6 (24–6). Ici, le circuit complet est divisé en 4 sous-circuits de 6 qubits. Chaque bloc encode 6 features et applique un ansatz paramétré plus expressif que dans le modèle 4-qubits. Ce modèle constitue un compromis entre découpe, capacité de représentation et coût de recomposition.

Modèle Cut-8 (24–8). Ce modèle découpe les 24 qubits en 3 sous-circuits de 8 qubits. Le nombre de fragments est plus faible, mais chaque bloc nécessite davantage de qubits, ce qui impose des contraintes matérielles plus fortes. Ce scénario permet d’analyser l’effet d’une architecture plus large par fragment sur la stabilité des résultats.

Modèle Amplitude (5 qubits). Ce modèle utilise un encodage par amplitudes sur 5 qubits. Pour respecter la dimension $2^5 = 32$, un sous-ensemble de 32 caractéristiques du dataset est sélectionné et normalisé, puis injecté directement comme vecteur d’amplitude.

Modèle PCA (5 composantes). Dans ce modèle, les données d’entrée sont réduites à 5 composantes principales via PCA avant d’être encodées sur 5 qubits, un feature par qubit via rotation. Ce modèle réduit fortement la dimension des données tout en conservant les variations les plus représentatives. Il constitue la seconde architecture de référence non découpée.

Modèle	Qubits par fragment	Nb. de sous-circuits	Encodage	Nb. features
Cut-4 (24–4)	4	6	Angulaire	24
Cut-6 (24–6)	6	4	Angulaire	24
Cut-8 (24–8)	8	3	Angulaire	24
Amplitude	5	1	Amplitude	32
PCA	5	1	Angulaire	5

TABLEAU 4.1 Résumé des modèles évalués : taille des sous-circuits, encodage et nombre de features utilisés.

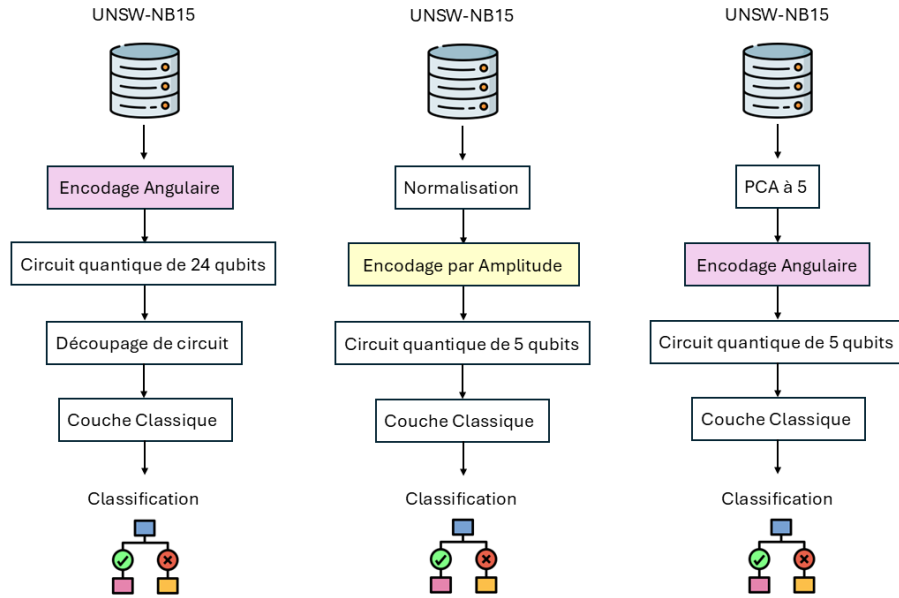


FIGURE 4.2 Modèles évalués dans les expérimentations

4.2 Résultats

Le tableau 4.2 résume les paramètres expérimentaux utilisés pour l’entraînement des modèles quantiques. Les expériences ont été réalisées à l’aide du cadre de calcul PennyLane, exécuté sur une machine TPU v6e-1 afin d’accélérer la phase d’optimisation. Le modèle exploite l’interface TensorFlow Keras pour l’intégration des couches hybrides classiques et quantiques. Le jeu de données UNSW-NB15 a été employé pour la détection d’anomalies réseau, avec deux types d’encodage — angulaire et par amplitude — afin de comparer la qualité de représentation des entrées. L’optimisation a été effectuée à l’aide de l’algorithme Adam sur 100 époques, avec une taille de lot de 32 et un taux d’apprentissage fixé à 3×10^{-3}

TABLEAU 4.2 Détails expérimentaux des modèles quantiques

Élément	Détail de l'expérience
Cadre de calcul quantique	<i>PennyLane</i>
Machine d'exécution	<i>TPU v6e-1</i>
Interface d'apprentissage profond	<i>TensorFlow Keras API</i>
Jeu de données	<i>UNSW-NB15</i>
Type d'encodage	<i>Angulaire et Amplitude</i>
Optimiseur	<i>Adam</i>
Nombre d'époques	100
Taille de batch	32
Taux d'apprentissage	3×10^{-3}

4.2.1 Métriques d'évaluation des modèles

Précision

Mesure la proportion de prédictions correctes.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

F1-score

Évalue l'équilibre entre précision et rappel, utile en cas de déséquilibre.

$$\text{Precision} = \frac{TP}{TP + FP}, \quad \text{Recall} = \frac{TP}{TP + FN}$$

$$\text{F1} = 2 \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

MCC (Matthews Correlation Coefficient)

Métrique intégrant toutes les erreurs, adaptée aux datasets déséquilibrés.

$$\text{MCC} = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

Valeurs entre -1 (mauvais) et $+1$ (parfait), 0 indique le hasard.

AUC-ROC

Mesure la capacité du modèle à distinguer les classes sur tous les seuils possibles.

$$\text{TPR} = \frac{TP}{TP + FN}, \quad \text{FPR} = \frac{FP}{FP + TN}$$

L'AUC correspond à l'aire sous la courbe TPR-FPR (0.5 à 1).

AUC-PR

Plus informative que l'AUC-ROC dans les contextes déséquilibrés. Elle quantifie la relation entre précision et rappel :

$$\text{AUC-PR} = \int_0^1 \text{Precision}(\text{Recall}) d\text{Recall}.$$

4.2.2 Comportement à l'entraînement

Les métriques d'entraînement ont été regroupées dans trois graphiques : la précision, la perte et l'AUC-PR.

La courbe de précision montre que les modèles découpés surperforment systématiquement les approches classiques. Cut-6 atteint les meilleures valeurs et la progression la plus régulière, suivi de Cut-8. Cut-4 reste performant mais limité par une expressivité réduite. PCA et l'encodage amplitude obtiennent les plus faibles précisions et convergent plus lentement.

La courbe de perte confirme ces résultats : Cut-6 converge rapidement vers la perte la plus faible, Cut-8 suit avec une marge modérée, tandis que Cut-4 atteint un plateau prématuré. PCA et amplitude encoding présentent des pertes plus élevées et une optimisation moins efficace.

L'AUC-PR, métrique adaptée au caractère déséquilibré du dataset UNSW-NB15, renforce ces observations. Cut-6 obtient les meilleures valeurs, indiquant une forte capacité à identifier correctement les attaques. Cut-8 reste proche mais légèrement en retrait. Cut-4 et PCA montrent des performances moyennes, tandis que l'encodage amplitude est nettement inférieur.

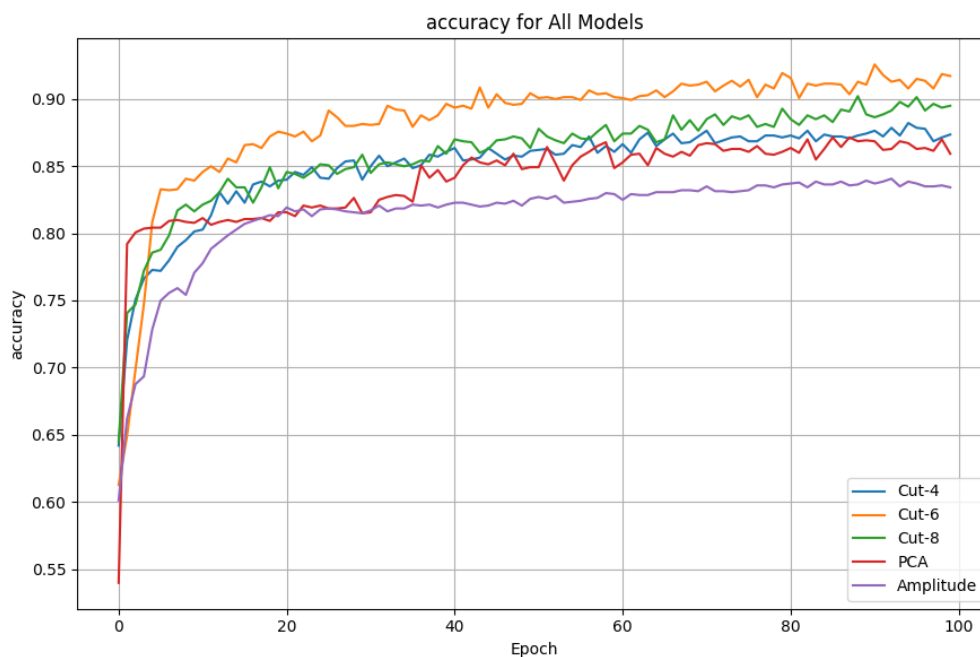


FIGURE 4.3 Précision d'entraînement pour les cinq modèles




FIGURE 4.4 Perte d'entraînement pour les cinq modèles

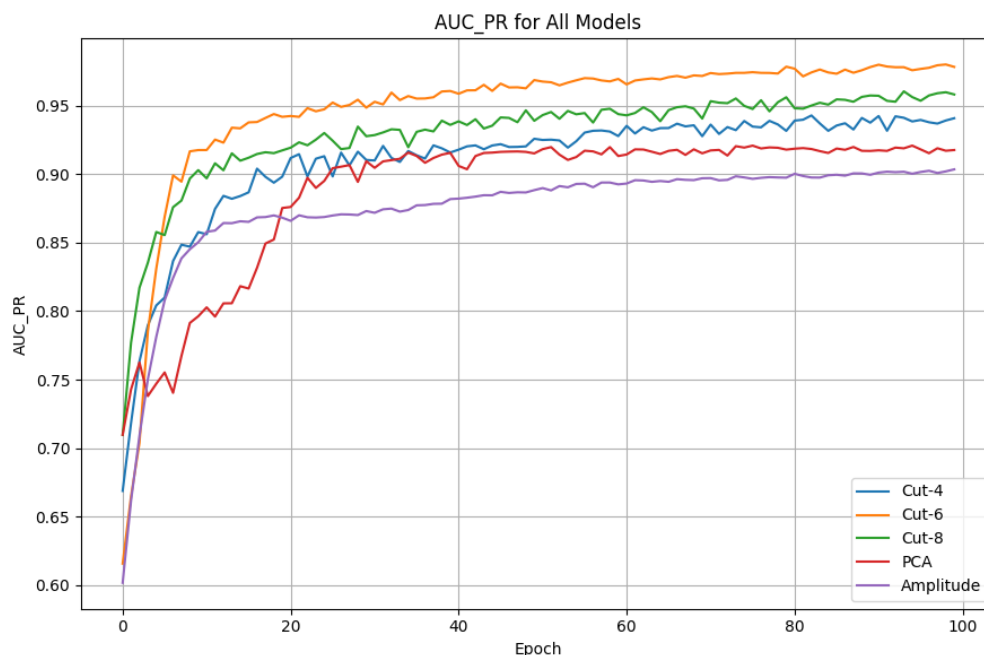


FIGURE 4.5 AUC-PR d'entraînement pour les cinq modèles

4.2.3 Performances globales sur le test

Les performances des cinq modèles sur les données de test sont résumées dans le Tableau 4.3. Les métriques présentées incluent l'Accuracy, le F1-score, le MCC, l'AUC-ROC et l'AUC-PR, permettant d'évaluer à la fois la qualité globale des prédictions et la capacité des modèles à distinguer les classes positives.

Cut-6 obtient les meilleurs résultats sur l'ensemble des métriques : Accuracy (0.8767), F1-score (0.8746), MCC (0.7538), AUC-ROC (0.9245) et AUC-PR (0.9328). Cut-4 et Cut-8 suivent avec des performances proches, confirmant que la découpe du circuit ne dégrade pas la généralisation. L'encodage amplitude maintient des valeurs correctes mais inférieures aux modèles découpés. PCA est nettement en retrait, avec des métriques plus faibles, en particulier un MCC très bas (0.1896) indiquant une mauvaise séparation des classes.

TABLEAU 4.3 Performances sur le jeu de test pour chaque modèle

Modèle	Accuracy	F1-score	MCC	AUC_ROC	AUC_PR
Cut-4	0.8567	0.8517	0.7149	0.9059	0.8985
Cut-6	0.8767	0.8746	0.7537	0.9245	0.9328
Cut-8	0.8517	0.8484	0.7040	0.9269	0.8909
PCA	0.5533	0.6840	0.1896	0.6537	0.6683
Amplitude	0.8117	0.8285	0.6357	0.8985	0.8902

TABLEAU 4.4 Meilleures métriques d'entraînement pour chaque modèle

Modèle	AUC_PR	AUC_ROC	Accuracy	Loss
Cut-4	0.942821	0.942494	0.882059	0.302551
Cut-6	0.980014	0.978297	0.925661	0.188569
Cut-8	0.960403	0.962641	0.902073	0.243428
PCA	0.920797	0.936550	0.871337	0.310968
Amplitude	0.903475	0.913830	0.840600	0.363708

4.2.4 Discussion des résultats

Les résultats montrent que la découpe du circuit améliore la généralisation. Cut-6 apparaît comme la configuration optimale : il atteint les meilleures valeurs dans toutes les métriques, ce qui suggère que six qubits par fragment offrent un bon équilibre entre expressivité et stabilité.

Cut-4 et Cut-8 restent performants mais légèrement en dessous. Cut-4 souffre probablement d'une expressivité insuffisante, tandis que Cut-8 augmente la complexité sans gain notable. L'encodage amplitude fournit des résultats corrects mais reste dominé par les modèles découpés. PCA obtient les performances les plus faibles : la réduction dimensionnelle élimine des informations essentielles, ce qui se reflète particulièrement dans le MCC et l'AUC-PR.

4.2.5 Analyse complémentaire

Complexité et ressources. Les modèles découpés nécessitent entre 3 et 6 sous-circuits selon la configuration (Cut-8, Cut-6, Cut-4). La profondeur unitaire reste limitée, mais le coût de recomposition augmente avec le nombre de coupes. Le modèle Cut-6 utilise environ quatre fois plus de paramètres qu'Amplitude (5 qubits) mais reste simulable dans un temps raisonnable.

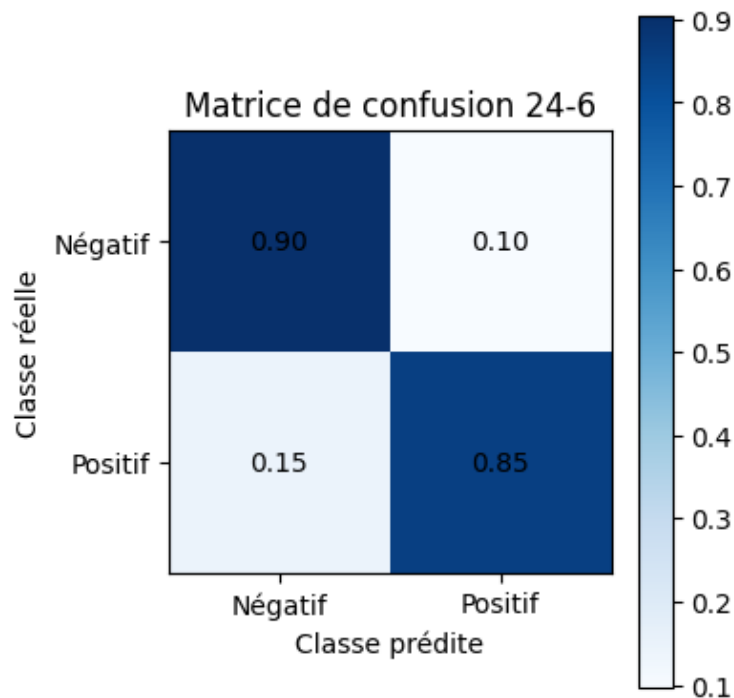


FIGURE 4.6 Matrice de Confusion pour 24-6

Limites du protocole. L'étude repose sur un échantillon réduit à 2000 exemples pour rendre la simulation quantique tractable. Aucun test n'a été effectué sur du matériel quantique réel, et les performances pourraient être différentes en présence de bruit physique. Des splits multiples ou une validation croisée permettraient de mieux évaluer la stabilité des résultats.

CHAPITRE 5 CONCLUSION

5.1 Récapitulatif du travail

Ce mémoire a évalué l'utilisation du circuit cutting comme solution pour exécuter des architectures HQNN sur un matériel quantique limité. L'étude a montré que la décomposition de circuits permet de réduire la complexité du modèle tout en conservant des performances élevées sur le dataset *UNSW-NB15*. Les résultats obtenus répondent aux questions de recherche : le circuit cutting permet l'exécution de modèles hybrides sur un nombre réduit de qubits, il peut maintenir la performance sans perte significative, et il constitue une alternative crédible aux méthodes classiques de réduction de dimension.

5.2 Contributions principales

- Démonstration expérimentale qu'une architecture découpée 24–6 maintient, voire améliore, la performance par rapport au modèle complet utilisant l'encodage amplitude.
- Mise en évidence des limites d'un PCA trop agressif sur *UNSW-NB15*, entraînant une dégradation nette des métriques de classification.
- Proposition d'une architecture HQNN découpée, répliquable et adaptable à d'autres jeux de données réseau, sans dépendance au nombre total de qubits physiques.

5.3 Limites du mémoire

- Les expériences ont été réalisées exclusivement en simulation, sans validation sur un hardware quantique réel, ce qui empêche de mesurer l'impact du bruit physique.
- Le découpage repose sur une structure fixe, sans optimisation automatique des coupes ni recherche systématique de partitions efficaces.
- L'évaluation a été effectuée sur un sous-échantillon de 2000 exemples, sans validation croisée ni intervalles de confiance, ce qui limite l'analyse statistique.
- Le dataset *UNSW-NB15* ne couvre pas l'ensemble de la diversité des environnements réseau réels.

5.4 Perspectives de recherche

- Développer des méthodes d'optimisation automatique des coupes pour dépasser les

- heuristiques fixes, en réponse à la limite actuelle d’absence d’exploration systématique.
- Étendre l’analyse à d’autres datasets réseau (IoT, 5G) afin de tester la généralisabilité du HQNN découpé et compenser la limitation liée à l’usage unique d’UNSW-NB15.
 - Intégrer la décomposition dans des approches de quantum federated learning pour exploiter naturellement le caractère distribué des sous-circuits.
 - Valider l’approche sur du matériel quantique réel, afin de confronter les résultats simulés aux contraintes physiques (bruit, temps de cohérence).

5.5 Conclusion générale

La décomposition de circuits apparaît comme une solution pertinente pour exécuter des HQNN sur des ressources quantiques limitées, tout en maintenant des performances compétitives sur *UNSW-NB15*. Les résultats montrent que le circuit cutting, en particulier la configuration 24–6, permet d’obtenir des modèles stables et efficaces. Des travaux futurs restent nécessaires pour optimiser automatiquement les coupes et valider expérimentalement ces approches sur du matériel quantique réel.

RÉFÉRENCES

- [1] L. K. Grover, “A fast quantum mechanical algorithm for database search,” dans *Proceedings of the twenty-eighth annual ACM symposium on Theory of computing*, 1996, p. 212–219.
- [2] P. W. Shor, “Algorithms for quantum computation : discrete logarithms and factoring,” dans *Proceedings 35th annual symposium on foundations of computer science*. Ieee, 1994, p. 124–134.
- [3] F. Arute *et al.*, “Quantum supremacy using a programmable superconducting processor,” *Nature*, vol. 574, n°. 7779, p. 505–510, 2019.
- [4] I. F. Araujo *et al.*, “A divide-and-conquer algorithm for quantum state preparation,” *Scientific reports*, vol. 11, n°. 1, p. 6329, 2021.
- [5] B. Pokharel et D. A. Lidar, “Demonstration of algorithmic quantum speedup,” *Physical Review Letters*, vol. 130, n°. 21, p. 210602, 2023.
- [6] J. Preskill, “Quantum computing in the nisq era and beyond,” *Quantum*, vol. 2, p. 79, 2018.
- [7] K. Zaman *et al.*, “A survey on quantum machine learning : Current trends, challenges, opportunities, and the road ahead,” *arXiv preprint arXiv :2310.10315*, 2023.
- [8] R. L’Abbate *et al.*, “A quantum-classical collaborative training architecture based on quantum state fidelity,” *IEEE Transactions on Quantum Engineering*, vol. 5, p. 1–14, 2024.
- [9] M. Kashif, E. Sychiuco et M. Shafique, “Investigating the effect of noise on the training performance of hybrid quantum neural networks,” dans *2024 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2024, p. 1–10.
- [10] M. Kashif et M. Shafique, “Hqnet : Harnessing quantum noise for effective training of quantum neural networks in nisq era,” *arXiv preprint arXiv :2402.08475*, 2024.
- [11] J. R. McClean *et al.*, “Barren plateaus in quantum neural network training landscapes,” *Nature communications*, vol. 9, n°. 1, p. 4812, 2018.
- [12] T. Peng *et al.*, “Simulating large quantum circuits on a small quantum computer,” *Physical review letters*, vol. 125, n°. 15, p. 150504, 2020.
- [13] M. Rath et H. Date, “Quantum data encoding : A comparative analysis of classical-to-quantum mapping techniques and their impact on machine learning accuracy,” *EPJ Quantum Technology*, vol. 11, n°. 1, p. 72, 2024.

- [14] N. Moustafa et J. Slay, “Unsw-nb15 : a comprehensive data set for network intrusion detection systems (unsw-nb15 network data set),” dans *2015 military communications and information systems conference (MilCIS)*. IEEE, 2015, p. 1–6.
- [15] W. Hammami, S. Cherkaoui et S. Wang, “Enhancing network anomaly detection with quantum gans and successive data injection for multivariate time series,” dans *2025 International Wireless Communications and Mobile Computing (IWCMC)*, 2025, p. 1667–1672.
- [16] H. Hotelling, “Analysis of a complex of statistical variables into principal components.” *Journal of educational psychology*, vol. 24, n^o. 6, p. 417, 1933.
- [17] H. Bourlard et Y. Kamp, “Auto-association by multilayer perceptrons and singular value decomposition,” *Biological cybernetics*, vol. 59, n^o. 4, p. 291–294, 1988.
- [18] W. Tang *et al.*, “Cutqc : using small quantum computers for large quantum circuit evaluations,” dans *Proceedings of the 26th ACM International conference on architectural support for programming languages and operating systems*, 2021, p. 473–486.
- [19] A. Lowe *et al.*, “Fast quantum circuit cutting with randomized measurements,” *Quantum*, vol. 7, p. 934, 2023.
- [20] C. Piveteau et D. Sutter, “Circuit knitting with classical communication,” *IEEE Transactions on Information Theory*, vol. 70, n^o. 4, p. 2734–2745, 2023.
- [21] M. Bechtold *et al.*, “Cutting a wire with non-maximally entangled states,” dans *2024 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW)*. IEEE, 2024, p. 1136–1145.
- [22] M. A. Perlin *et al.*, “Quantum circuit cutting with maximum-likelihood tomography,” *npj Quantum Information*, vol. 7, n^o. 1, p. 64, 2021.
- [23] S. Brandhofer, I. Polian et K. Krsulich, “Optimal partitioning of quantum circuits using gate cuts and wire cuts,” *IEEE Transactions on Quantum Engineering*, vol. 5, p. 1–10, 2023.
- [24] W. Cambiucci, R. M. Silveira et W. V. Ruggiero, “Spatial and temporal circuit cutting with hypergraphic partitioning,” *arXiv preprint arXiv :2504.09334*, 2025.
- [25] S. Sweeney et K. Guha, “Dynamic hypergraph partitioning of quantum circuits with hybrid execution,” *arXiv preprint arXiv :2506.09963*, 2025.
- [26] A. Gouveia et M. Correia, “Towards quantum-enhanced machine learning for network intrusion detection,” dans *2020 IEEE 19th international symposium on Network Computing and Applications (NCA)*. IEEE, 2020, p. 1–8.

- [27] A. Kadi *et al.*, “An in-depth comparative study of quantum-classical encoding methods for network intrusion detection,” *IEEE Open Journal of the Communications Society*, 2025.
- [28] C. Gong *et al.*, “Network intrusion detection based on variational quantum convolution neural network.” *Journal of Supercomputing*, vol. 80, n°. 9, 2024.
- [29] A. Marchisio *et al.*, “Cutting is all you need : Execution of large-scale quantum neural networks on limited-qubit devices,” *arXiv preprint arXiv :2412.04844*, 2024.
- [30] D. Abreu, C. E. Rothenberg et A. Abelém, “Qml-ids : Quantum machine learning intrusion detection system,” dans *2024 IEEE Symposium on Computers and communications (ISCC)*. IEEE, 2024, p. 1–6.
- [31] I. Chinthlagattu, “Quantum-enhanced intrusion detection systems for wireless router networks : A novel framework using quantum autoencoders and quantum gans,” *Available at SSRN 5416898*, 2025.
- [32] S. Chao, G. Yang et M. Nie, “Hybrid continuous variational quantum neural networks for network intrusion detection,” dans *Industrial Engineering and Applications*. IOS Press, 2023, p. 366–378.
- [33] N. Moustafa et J. Slay, “The evaluation of network anomaly detection systems : Statistical analysis of the unsw-nb15 data set and the comparison with the kdd99 data set,” *Information Security Journal : A Global Perspective*, vol. 25, n°. 1-3, p. 18–31, 2016.