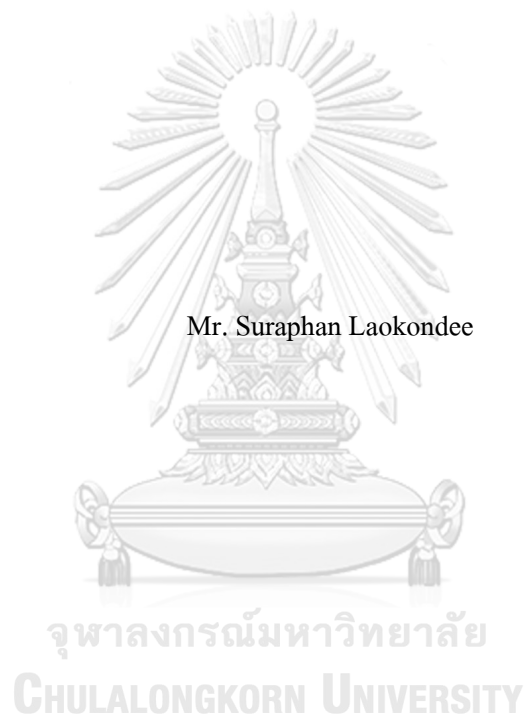


โมเดลควอนตัม โครงข่ายประสาทเทียมสำหรับปัญหาการถดถอย



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมคอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2564
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Quantum neural network model for regression problems



Mr. Suraphan Laokondee

A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering in Computer Engineering

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2021

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	โมเดลควอนตัมโครงข่ายประสาทเทียมสำหรับปัญหาการถดถอย
โดย	นายสุรพันธุ์ เหล่าคนดี
สาขาวิชา	วิศวกรรมคอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ศาสตราจารย์ ดร.ประภาส จงสิตย์วัฒนา

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(รองศาสตราจารย์ ดร.เศรษฐา ปานงาม)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ศาสตราจารย์ ดร.ประภาส จงสิตย์วัฒนา)

..... กรรมการภายนอกมหาวิทยาลัย
(ศาสตราจารย์ ดร.ณชล ไชยรัตน์)

CHULALONGKORN UNIVERSITY

สุรพันธุ์ เหล่าคนดี : โมเดลควอนตัมโครงข่ายประสาทเทียมสำหรับปัญหาการถดถอย.
 (Quantum neural network model for regression problems) อ.ที่ปรึกษาหลัก : ศ. ดร.
 ประภาส จงสฤษดิ์วัฒนา

ควอนตัมคอมพิวเตอร์ได้แสดงให้เห็นถึงความสามารถที่เหนือกว่าคอมพิวเตอร์แบบคลาสสิกในการแก้ไขปัญหาบางประเภทด้วยการใช้กฎของกลศาสตร์ควอนตัมและด้วยการรวมเอาความรู้ทางด้านทฤษฎีการเรียนรู้ของเครื่องและควอนตัมคอมพิวเตอร์ทำให้เกิดองค์ความรู้ใหม่ที่เรียกว่าการเรียนรู้ของเครื่องแบบควอนตัม ควอนตัมโครงข่ายประสาทเทียมเป็นหนึ่งในรูปแบบของการใช้ความรู้ของการเรียนรู้ของเครื่องและคอมพิวเตอร์ควอนตัมด้วยการคิดแปลงความคิดจากการทำโครงข่ายประสาทเทียมแบบคลาสสิกและการใช้ควอนตัมเกตแบบปรับค่าได้มาเป็นค่าน้ำหนักของโครงข่ายประสาทเทียม

ในงานวิจัยนี้ได้นำเสนอการประยุกต์ใช้ควอนตัมโครงข่ายประสาทเทียมด้วยข้อมูลจากโลกจริงเพื่อแก้ไขปัญหาการถดถอยเพื่อทำนายจำนวน โทเคนที่ใช้ในระบบประมวลรายวิชา โดยการทดลองจะถูกทำบนเครื่องจำลองคอมพิวเตอร์ควอนตัมของไอบีเอ็ม(Qiskit) ผลลัพธ์ของการทดลองได้แสดงให้เห็นว่าควอนตัมโครงข่ายประสาทเทียมสามารถบรรลุผลที่ดีในการทำนายเมื่อเปรียบเทียบกับโครงข่ายประสาทเทียมแบบคลาสสิกโดยโมเดลที่ดีที่สุดมีค่าราคาที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง(RMSE) ที่ 6.38% วิธีการนี้ทำให้เกิดการเปิดกว้างสำหรับโอกาสที่จะสำรวจผลประโยชน์ของการเรียนรู้ของเครื่องแบบควอนตัมในการทำวิจัยในอนาคต

จุฬาลงกรณ์มหาวิทยาลัย
 CHULALONGKORN UNIVERSITY

สาขาวิชา วิศวกรรมคอมพิวเตอร์
 ปีการศึกษา 2564

ลายมือชื่อนิติ
 ลายมือชื่อ อ.ที่ปรึกษาหลัก

6372122221 : MAJOR COMPUTER ENGINEERING

KEYWORD: Quantum Computing, Quantum Neural Network, Neural Networks, Course
Bidding, Bid allocation, regression problem

Suraphan Laokondee : Quantum neural network model for regression problems.

Advisor: Prof. PRABHAS CHONGSTITVATANA, Ph.D.

Quantum computer has shown the advantage over the classical computer to solve some problems using the laws of quantum mechanics. With a combination of knowledge of machine learning and quantum computing, Quantum neural networks adapted the concept from classical neural networks and apply parameterized quantum gates as neural network weights. In this paper, we present an application of quantum neural networks with real-world data to predict token price used in a course bidding system. The experiments were carried out on the Qiskit quantum simulator. The result shows that quantum neural networks can achieve a good prediction result compared to the classical neural network. The best model configuration has the lowest RMSE 6.38%. This approach opens an opportunity to explore the benefit of quantum machine learning in many research fields in the future.



Field of Study: Computer Engineering

Student's Signature

Academic Year: 2021

Advisor's Signature

กิตติกรรมประกาศ

งานวิจัยฉบับนี้สำเร็จลุล่วงได้ด้วยความอนุเคราะห์จากอาจารย์ที่ปรึกษาวิจัย ศาสตราจารย์ ดร. ประภาส จงสฤษดิ์วัฒนา อาจารย์ประจำภาควิชาวิศวกรรมคอมพิวเตอร์ จุฬาลงกรณ์มหาวิทยาลัย สำหรับคำแนะนำและแนวคิดในการทำวิทยานิพนธ์ตลอดจนทักษะแนวทางการแก้ไขปัญหา รวมถึงการสนับสนุนการวิจัยที่ดีมาโดยตลอด ขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้ด้วย

ขอขอบคุณ รองศาสตราจารย์ ดร. เศรษฐา ปานงาม ประธานกรรมการสอบวิทยานิพนธ์ และ ศาสตราจารย์ ดร. ณชล ไชยรัตน์ กรรมการสอบวิทยานิพนธ์ที่ได้ให้คำแนะนำ ข้อชี้แนะแนวทางและคอยให้คำปรึกษาที่ดีในการทำงานวิจัย

สุดท้ายนี้ขอขอบคุณครอบครัวที่คอยให้การช่วยเหลือและกำลังใจในการทำวิจัยและการสนับสนุนที่ดีมาโดยตลอด

สุรพันธุ์ เหล่าคนดี

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฉ
สารบัญรูปภาพ.....	ญ
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	2
1.3 ขอบเขตงานวิจัย.....	2
1.4 ขั้นตอนและวิธีการดำเนินการวิจัย.....	3
1.5 คุณค่าทางวิชาการและประโยชน์ที่คาดว่าจะได้รับจากการวิจัย.....	3
1.6 แผนการดำเนินการวิจัย.....	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 ควอนตัมคอมพิวเตอร์ (Quantum computer).....	5
2.1.1 ควอนตัมบิต (Quantum Bits).....	5
2.1.2 การคำนวณเชิงควอนตัมด้วยโมเดลวงจรควอนตัม (Quantum circuit model of computation).....	5
2.1.2.1 ควอนตัมเกตประเภทคิวบิตเดี่ยว (Single Qubit gate).....	6

2.1.2.2	ควอนตัมเกตประเภทหลายคิวบิต (Multi Qubit gate)	7
2.1.2.3	ควอนตัมเกตแบบปรับค่าได้ (Parameterized gate)	8
2.2	อัลกอริทึมควอนตัม (Quantum Algorithm)	8
2.3	อัลกอริทึมควอนตัมแบบเปลี่ยนแปลง (Variational quantum algorithm)	8
2.4	ปัญหาการถดถอย (Regression problems)	9
2.5	งานวิจัยที่เกี่ยวข้อง	9
2.5.1	โมเดลการเรียนรู้ของเครื่องแบบควอนตัม (Quantum machine learning)	10
2.5.2	อัลกอริทึมควอนตัมแบบเปลี่ยนแปลง (Variational Quantum Algorithm)	10
2.5.3	วงจรควอนตัมแบบปรับค่าได้มาเป็นโมเดลการเรียนรู้ (Parameterized quantum circuits as machine learning)	11
2.5.4	ควอนตัมโครงข่ายประสาทเทียม (Quantum neural networks)	11
บทที่ 3	วิธีดำเนินการวิจัย	13
3.1	ข้อมูลที่ใช้ในการศึกษา (Training Data)	13
3.1.1	ข้อมูลจากระบบประมวลผลวิชาตั้งแต่ปี 2015 จนถึง 2019	13
3.1.2	ข้อมูลรายงานผู้ติดเชื้อโควิด 2019 ในประเทศไทย	13
3.2	การเข้ารหัสข้อมูล (Data Encoding)	15
3.3	โมเดลควอนตัมโครงข่ายประสาทเทียม (Quantum Neural network model)	16
3.4	การสอนโมเดลและการเพิ่มประสิทธิภาพ (Model training and Optimization)	17
3.5	การแบ่งข้อมูลชุดสำหรับการสอนและชุดทดสอบ (Train-Test data split)	18
3.6	การประเมินผล (Model Evaluation)	18
3.7	กระบวนการสอน (Training process)	18
บทที่ 4	ผลการวิจัย	20
4.1	ผลการวิจัยการทำนายการจัดสรรโทเคนในระบบประมวลผลรายวิชา	20

4.2 ผลการวิจัยการทำนายจำนวนผู้ติดเชื้อโควิด 2019 ในวันถัดไป โดยใช้ข้อมูล 4 วันก่อนหน้า

21

บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	25
5.1 สรุปผลการวิจัย	25
5.2 ข้อเสนอแนะ	26
บรรณานุกรม.....	27
ประวัติผู้เขียน.....	30



สารบัญตาราง

หน้า

ตารางที่ 1 ตัวอย่างชุดตัวแปรนำเข้าและตัวแปรเป้าหมายสำหรับข้อมูลชุดที่ 1 จากระบบประมวล รายวิชา	13
ตารางที่ 2 ผลการใช้ชุดทดสอบจากข้อมูลการประเมินการจัดสรรโทเคนสำหรับการประมวลวิชา .	21
ตารางที่ 3 ผลการใช้ชุดทดสอบจากข้อมูลผู้ป่วยโควิด 2019 ในประเทศไทยด้วยโมเดลควอนตัม โครงข่ายประสาทเทียม	23
ตารางที่ 4 ผลการใช้ชุดข้อมูลทดสอบจากข้อมูลผู้ป่วยโควิด 2019 ในประเทศไทยด้วยโมเดล โครงข่ายประสาทเทียมแบบคลาสสิก	23

สารบัญรูปภาพ

	หน้า
ภาพที่ 1 ตัวอย่างข้อมูลจากระบบประมวลรายวิชา	14
ภาพที่ 2 Correlation Matrix ของข้อมูลจากระบบประมวลรายวิชา	14
ภาพที่ 3 กราฟแสดงข้อมูลชุดที่ 2 ข้อมูลผู้ติดเชื้อโควิด 2019 ในประเทศไทย.....	14
ภาพที่ 4 ตัวอย่างข้อมูลผู้ติดเชื้อโควิด 2019 ในแต่ละวัน	15
ภาพที่ 5 วงจร Second-order Pauli-Z evolution circuit (ZZFeatureMap).....	16
ภาพที่ 6 วงจร RealAmplitudes circuit ที่มี 2 วงจรซ้ำ	17
ภาพที่ 7 ภาพรวมของกระบวนการสอนโมเดลควอนตัมโครงข่ายประสาทเทียม.....	18
ภาพที่ 8 แผนภาพแสดงขั้นตอนการสอนโมเดลควอนตัมโครงข่ายประสาทเทียม	19
ภาพที่ 9 ผลการสอนโมเดลจากข้อมูลชุดที่ 1 ด้วยไฮเปอร์พารามิเตอร์ชุดที่ 1	20
ภาพที่ 10 ผลการสอนโมเดลจากข้อมูลชุดที่ 1 ด้วยไฮเปอร์พารามิเตอร์ชุดที่ 2	20
ภาพที่ 11 ผลการสอน โมเดลจากข้อมูลชุดที่ 2.....	22
ภาพที่ 12 ผลการทำนายข้อมูลผู้ป่วยโควิด 2019 ในประเทศไทยด้วยโมเดลควอนตัมโครงข่ายประสาทเทียม	24

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ควอนตัมเทคโนโลยีและควอนตัมคอมพิวเตอร์ในปัจจุบันนั้นมีการพัฒนาไปอย่างรวดเร็วและก้าวหน้าขึ้นมากจึงทำให้การทำความเข้าใจและนำเทคโนโลยีนี้มาประยุกต์ใช้นั้นเป็นสิ่งที่สำคัญ อีกทั้งเราควรรู้ว่าควอนตัมคอมพิวเตอร์สามารถให้ประโยชน์กับงานชนิดใดได้ดี เพื่อให้เราสามารถใช้ประโยชน์ความได้เปรียบตรงนี้ในการพัฒนาโปรแกรมประเภทต่าง ๆ ที่ใช้เทคโนโลยีควอนตัมในอนาคตได้อย่างมีประสิทธิภาพ

ควอนตัมคอมพิวเตอร์นั้นใช้หลักการกลศาสตร์ควอนตัม (Quantum mechanics) ที่สามารถอธิบายผลการทดลองและปรากฏการณ์ต่าง ๆ ที่กลศาสตร์นิวตันไม่สามารถอธิบายได้กับวัตถุที่มีขนาดเล็กกว่าอะตอม โดยคุณสมบัติสำคัญอย่างเช่น หลักการความพัวพันเชิงควอนตัม (Quantum entanglement) และหลักการทับซ้อนทางควอนตัม (Quantum superposition) ที่สถานะทางควอนตัมสามารถเป็นได้ทั้ง 0 และ 1 ในเวลาเดียวกัน ถูกนำมาใช้สร้างเป็นคิวบิต (Qubits) ในควอนตัมคอมพิวเตอร์ และใช้คุณสมบัติที่กล่าวมาเป็นคุณสมบัติหลักเพื่อช่วยในการคำนวณให้ดีขึ้น

ในปัจจุบันนั้นยังเป็นที่ต้องพิสูจน์กันว่าควอนตัมคอมพิวเตอร์มีประสิทธิภาพสูงกว่าคอมพิวเตอร์คลาสสิกในด้านใดบ้าง และในปัญหาประเภทใดที่ควอนตัมคอมพิวเตอร์นั้นทำงานได้ดีกว่าคอมพิวเตอร์คลาสสิก ในขณะนี้มีหลาย ๆ งานวิจัยที่สามารถพิสูจน์ได้ว่าควอนตัมคอมพิวเตอร์นั้นสามารถแก้ปัญหาที่คอมพิวเตอร์คลาสสิกทำไม่ได้แต่สามารถทำได้บนควอนตัมคอมพิวเตอร์ เช่น การถอดรหัส RSA ด้วย Shor's algorithm และในบางปัญหาเช่น การนำควอนตัมคอมพิวเตอร์มาใช้ในเรื่องการเรียนรู้ของเครื่องมีแนวโน้มความเป็นไปได้ที่จะสามารถทำงานได้ดี จึงเกิดเป็นแนวคิดใหม่ที่กำลังเป็นที่สนใจ โดยนำความรู้ในการคำนวณแบบควอนตัมมาประยุกต์ใช้กับการเรียนรู้ของเครื่องโดยเรียกว่า Quantum machine learning

การใช้งานเทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence) และการเรียนรู้ของเครื่อง (Machine Learning) ถูกนำมาใช้อย่างแพร่หลายและเป็นวงกว้างไม่ว่าจะเป็นในอุตสาหกรรมการเงิน ธนาคาร สุขภาพ ฯลฯ การเรียนรู้ของเครื่องแบบควอนตัมสามารถช่วยให้เราแก้ปัญหาด้วยควอนตัมคอมพิวเตอร์ได้ดีกว่าคอมพิวเตอร์คลาสสิก ทั้งในแง่ของความเร็วในการเรียนรู้และความสามารถของโมเดล โดยควอนตัมโครงข่ายประสาทเทียม (Quantum neural network) เป็นหนึ่งในวิธีการเรียนรู้ของเครื่องแบบควอนตัม โดยตัวอัลกอริทึมที่ออกแบบมาให้สามารถใช้งานได้บนควอนตัมคอมพิวเตอร์ในยุคปัจจุบันซึ่งเป็นแบบ Noisy Intermediate-Scale Quantum

(NISQ) technology โดยตัวอัลกอริทึมจะใช้งานร่วมกันทั้งควอนตัมคอมพิวเตอร์และคอมพิวเตอร์คลาสสิกเพื่อให้เกิดประสิทธิภาพสูงสุด ควอนตัมคอมพิวเตอร์นั้นจะถูกใช้เป็นอุปกรณ์ในการเร่งความเร็วและใช้ควอนตัมอัลกอริทึมแบบแปรผัน (Variational quantum algorithms) ที่ใช้วงจรควอนตัมแบบฝึกได้ (Trainable quantum circuits) มาเป็นตัวโมเดลของการเรียนรู้

ในงานวิจัยชิ้นนี้จึงมุ่งเน้นการศึกษาทดลองการใช้ควอนตัมคอมพิวเตอร์และควอนตัมโครงข่ายประสาทเทียมมาใช้ในการสร้างโมเดลการเรียนรู้ของเครื่องที่ใช้ข้อมูลจริงจากระบบจัดสรรโทเคนสำหรับการประมูลรายวิชา เพื่อให้สามารถรู้ถึงความสามารถและศักยภาพของเครื่องควอนตัมคอมพิวเตอร์เมื่อเทียบกับคอมพิวเตอร์คลาสสิกในปัจจุบัน โดยเราจะใช้การจำลองเครื่องควอนตัมคอมพิวเตอร์ (Quantum simulator) จาก QISKIT ที่พัฒนาโดย IBM ในการทดสอบ

1.2 วัตถุประสงค์ของการวิจัย

- 1.2.1 เพื่อพัฒนาขั้นตอนวิธีการสร้างวงจรควอนตัมแบบปรับค่าได้เพื่อใช้ในการทำโมเดลการเรียนรู้ของเครื่อง
- 1.2.2 เพื่อปรับปรุงวิธีการออกแบบวงจรควอนตัมเพื่อใช้ในการแปลงข้อมูลแบบคลาสสิกให้เป็นสถานะทางควอนตัม
- 1.2.3 เพื่อเปรียบเทียบความสามารถและข้อจำกัดในการใช้วงจรควอนตัมในการสอนโมเดลการเรียนรู้ของเครื่อง

1.3 ขอบเขตงานวิจัย

- 1.3.1 งานวิจัยนี้นำข้อมูลจากระบบประมูลรายวิชาระหว่างปี 2015-2019 (5 ปี) จากคณะวิศวกรรมศาสตร์ ภาควิชาวิศวกรรมคอมพิวเตอร์ จุฬาลงกรณ์มหาวิทยาลัย
- 1.3.2 งานวิจัยนี้ศึกษาการใช้งาน Quantum Neural network เป็นโมเดลการเรียนรู้เพื่อแก้ปัญหา Regression ในการประเมินจำนวน token ที่ควร bid ในแต่ละวิชา
- 1.3.3 งานวิจัยนี้ใช้การจำลองควอนตัมคอมพิวเตอร์จาก IBM Qiskit Simulator เท่านั้น

1.4 ขั้นตอนและวิธีการดำเนินการวิจัย

- 1.4.1 ทำการสร้างวงจรคอนตัมสำหรับการ Encode ข้อมูลเข้าให้เป็นสถานะทางคอนตัม
- 1.4.2 ทำการสร้างวงจรคอนตัมสำหรับใช้เป็นโมเดลการเรียนรู้โดยใช้รูปแบบ Real Amplitudes circuit
- 1.4.3 นำเข้าข้อมูลจากระบบการประมวลผลรายวิชาโดยกำหนดให้ Token price เป็นเป้าหมายหรือข้อมูลที่เราจะทำการทำนาย และเลือกข้อมูลที่สำคัญที่สุด 4 ค่าขึ้นมาใช้ ตามตารางที่ 1.
- 1.4.4 กรองข้อมูลตามรายวิชาที่มีค่า Course interesting มากกว่า 2 โดยรายวิชาที่เหลือจะเป็นวิชาที่มีการแข่งขันในการลงทะเบียนเรียนสูง และเป็นการลดจำนวนข้อมูลที่จะนำไปใช้เพื่อช่วยลดเวลาในการสอนโมเดลการเรียนรู้แบบคอนตัมที่ใช้เวลานานในการจำลองด้วยคอมพิวเตอร์คลาสสิก
- 1.4.5 แยกข้อมูลออกเป็น 2 ชุด โดยแบ่งเป็น Training set และ Test set ในอัตราส่วน 70:30
- 1.4.6 ทำการสอน โมเดลด้วย Hyper parameter แบบต่าง ๆ เพื่อหาโครงสร้างที่มีความแม่นยำสูงสุด
- 1.4.7 สรุปผลและเปรียบเทียบผลจากโมเดลที่ได้

1.5 คุณค่าทางวิชาการและประโยชน์ที่คาดว่าจะได้รับจากการวิจัย

สิ่งที่คาดหวังจากงานวิจัยนี้คือสามารถใช้งานและสร้างคอนตัม โปรแกรมที่สามารถทำงานบนคอนตัมคอมพิวเตอร์เพื่อใช้ในการสอนการเรียนรู้ของเครื่องได้ และสามารถเปรียบเทียบและรู้ความสามารถของโมเดลการเรียนรู้ของเครื่องบนคอนตัมคอมพิวเตอร์และคอมพิวเตอร์คลาสสิก

ซึ่งคาดหวังว่าเราสามารถนำความรู้และความสามารถของคอนตัมคอมพิวเตอร์ที่สามารถแก้ไขปัญหาบางอย่างที่ดีกว่าคอมพิวเตอร์คลาสสิกไปช่วยในการสร้างโมเดลการเรียนรู้ที่ใช้เวลาในการสอนที่น้อยลงและได้โมเดลที่มีความสามารถและมีประสิทธิภาพที่ดีขึ้น

1.6 แผนการดำเนินการวิจัย

ขั้นตอนการดำเนินการวิจัย/ สัปดาห์	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	
1. ศึกษาการเขียนโปรแกรมควอนตัม แบบการใช้วงจรควอนตัม	■	■																	
2. ศึกษา Quantum optimization (QAOA)			■	■															
3. ทดลองสร้างโมเดล Quantum Neural network					■	■	■	■											
4. จัดทำโครงร่างวิทยานิพนธ์									■	■									
5. ทดลองสร้างโมเดลด้วยข้อมูลจาก ระบบ Token bidding											■	■							
6. วิเคราะห์และสรุปผลการวิจัย													■	■					
7. ดำเนินการตีพิมพ์บทความวิจัย																■	■		
8. ดำเนินการทำเล่มวิทยานิพนธ์ฉบับ สมบูรณ์																		■	■

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ควอนตัมคอมพิวเตอร์ (Quantum computer)

ในหัวข้อนี้เราจะพูดถึงพื้นฐานของการคำนวณแบบควอนตัมโดยเนื้อหาส่วนใหญ่จะยกมาจากหนังสือ Quantum Computation and Quantum Information [1] เขียนโดย Michael A. Nielsen & Isaac L. Chuang

2.1.1 ควอนตัมบิต (Quantum Bits)

ในคอมพิวเตอร์คลาสสิกหน่วยย่อยที่เล็กที่สุดของข้อมูลเรียกว่า บิต (Bit) แต่ในควอนตัมคอมพิวเตอร์จะใช้หน่วยที่เล็กที่สุดคือ คิวบิต (Qubit) โดยในคอมพิวเตอร์แบบคลาสสิกค่าของข้อมูลจะเป็นค่า 1 หรือ 0 ได้อย่างใดอย่างหนึ่งในแต่ละช่วงเวลา แต่ในควอนตัมคอมพิวเตอร์นั้นมีสิ่งที่เรียกว่า Quantum Superposition หรือการซ้อนทับของควอนตัมที่คิวบิตสามารถเป็นค่า 1 หรือ 0 ในเวลาเดียวกัน หรือมีความน่าจะเป็น 50:50 ที่จะเป็นค่า 1 หรือ 0 ซึ่งเราจะรู้ค่าจริงได้ก็ต่อเมื่อเราวัดค่าของคิวบิตและจะทำให้สถานะทางควอนตัมหายไป อีกคุณสมบัติที่ทำให้ควอนตัมคอมพิวเตอร์นั้นแตกต่างจากคอมพิวเตอร์คลาสสิกเป็นอย่างมากคือ Quantum Entanglement หรือการพัวพันในเชิงควอนตัมซึ่งมีลักษณะคือ อนุภาคหรือคิวบิตสามารถสื่อสารกันได้หรือส่งผลกระทบต่อกันได้โดยไม่ต้องผ่านตัวกลางแม้สองอนุภาคจะอยู่ห่างกันแค่ไหนก็ตาม

2.1.2 การคำนวณเชิงควอนตัมด้วยโมเดลวงจรควอนตัม (Quantum circuit model of computation)

การคำนวณแบบควอนตัมนั้นใช้การเปลี่ยนสถานะทางควอนตัมจากสถานะหนึ่งไปเป็นอีกสถานะหนึ่งโดยการใช้ควอนตัมเกตในการเปลี่ยนแปลงค่าหรือสถานะของคิวบิต ซึ่งควอนตัมเกตนั้นเป็นส่วนประกอบที่ทำให้เกิดเป็นวงจรควอนตัมที่เหมือนกับลอจิกเกต (Logic gate) ที่เป็นส่วนประกอบของวงจรดิจิทัล

ควอนตัมเกตมีลักษณะพิเศษที่สามารถทำการคำนวณแบบย้อนกลับได้ (Reversible computing) และเป็น Unitary Operator ที่สามารถแสดงด้วย Unitary matrices

$$U^*U = UU^* = I \text{ where } I \text{ is the identity element}$$

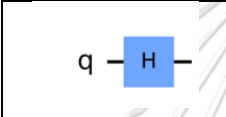
2.1.2.1 ควอนตัมเกตประเภทคิวบิตเดี่ยว (Single Qubit gate)

ควอนตัมเกตประเภทคิวบิตเดี่ยวเป็นควอนตัมเกตที่ทำงานกับหนึ่งคิวบิต โดยเป็นการเปลี่ยนสถานะของควอนตัมของแต่ละคิวบิต โดยควอนตัมเกตสามารถแสดงด้วยค่าแบบเมทริกซ์หรือเป็นลักษณะของการหมุนในแกน Bloch sphere หรือแผนภาพการนำเสนอสถานะทางควอนตัม

ตัวอย่างของควอนตัมเกตมาตรฐานที่มักถูกนำมาใช้ในวงจรควอนตัมและในงานวิจัยนี้

1. Hadamard Gate

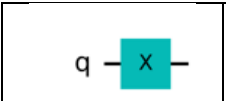
Hadamard gate หรือ H-gate เป็นควอนตัมเกตพื้นฐานที่ทำให้คิวบิตเปลี่ยนจากสถานะปกติไปเป็นสถานะ Superposition

	$H = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}$
--	--

2. Pauli gates

มีทั้งหมด 3 ประเภทคือ Pauli-X gate, Pauli-Y gate และ Pauli-Z gate ในแต่ละประเภทนั้นจะเป็นการหมุนคิวบิตตามแนวแกน x, y, z ใน Bloch sphere ไป π เรเดียน

Pauli-X gate นั้นจะเป็นควอนตัมเกตที่มีลักษณะเหมือนกับ NOT gate หรือ bit-flip ในคอมพิวเตอร์คลาสสิก โดยจะทำงานบน standard basis $|0\rangle$, $|1\rangle$ ทำหน้าที่สลับค่าจาก $|0\rangle$ ไปเป็น $|1\rangle$ และ $|1\rangle$ ไปเป็น $|0\rangle$

	$X = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$
---	--

Pauli-Y gate นั้นมีลักษณะคล้ายกับ Pauli-X gate แต่จะเป็นการหมุนในอีกแกนหนึ่งเป็นการสลับค่าจาก $|0\rangle$, ไปเป็นค่า $i|1\rangle$ และ $|1\rangle$ ไปเป็นค่า $-i|0\rangle$

q — Y —	$Y = \begin{bmatrix} 0 & -i \\ i & 0 \end{bmatrix}$
---	---

Pauli-Z gate จะไม่ทำอะไรกับ state $|0\rangle$ แต่จะเปลี่ยน $|1\rangle$ ไปเป็น $-|1\rangle$
จากลักษณะนี้บางครั้งเราจะเรียกว่า Phase-flip

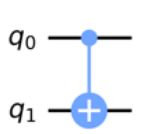
q — Z —	$Z = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$
---	---

2.1.2.2 ควอนตัมเกตประเภทหลายคิวบิต (Multi Qubit gate)

ควอนตัมเกตประเภทหลายคิวบิตนั้นเป็นควอนตัมเกตที่ทำงานกับหลาย ๆ คิวบิตเพื่อใช้ประโยชน์และความสามารถของ Entanglement ระหว่างหลาย ๆ คิวบิต

Controlled Not หรือ CNOT ทำงานบน 2 คิวบิต โดยใช้คิวบิตแรกเป็นตัวกำหนดว่าจะพลิกหรือกลับค่าคิวบิตที่สองหรือไม่ โดยเงื่อนไขคือถ้าคิวบิตแรกมีสถานะเป็น $|1\rangle$ จะกลับค่าคิวบิตที่ 2

Before		After	
Control	Target	Control	Target
$ 0\rangle$	$ 0\rangle$	$ 0\rangle$	$ 0\rangle$
$ 0\rangle$	$ 1\rangle$	$ 0\rangle$	$ 1\rangle$
$ 1\rangle$	$ 0\rangle$	$ 1\rangle$	$ 1\rangle$
$ 1\rangle$	$ 1\rangle$	$ 1\rangle$	$ 0\rangle$

 <p style="margin: 0;">q_0 — • — q_1 — + —</p>	$CNOT = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$
---	---

2.1.2.3 ควอนตัมเกตแบบปรับค่าได้ (Parameterized gate)

Parameterized gate หรือควอนตัมเกตแบบปรับค่าได้เป็นควอนตัมเกตแบบชนิดพิเศษ โดยในการใช้งานเราสามารถกำหนดคองศาของการหมุนได้ ลักษณะจะคล้ายกับ Pauli gates แต่จะสามารถกำหนดคองศาในการหมุนได้ โดยจะมี 3 ประเภท คือ R_x, R_y, R_z

q1 R_x $\pi/2$	$R_x(\theta) = \begin{bmatrix} \cos(\theta/2) & -i \sin(\theta/2) \\ -i \sin(\theta/2) & \cos(\theta/2) \end{bmatrix}$
q0 R_y $\pi/2$	$R_y(\theta) = \begin{bmatrix} \cos(\theta/2) & -\sin(\theta/2) \\ \sin(\theta/2) & \cos(\theta/2) \end{bmatrix}$
q2 R_z $\pi/2$	$R_z(\theta) = \begin{bmatrix} \exp(-i\theta/2) & 0 \\ 0 & \exp(i\theta/2) \end{bmatrix}$

2.2 อัลกอริทึมควอนตัม (Quantum Algorithm)

ในการคำนวณแบบควอนตัมนั้นจะใช้ Quantum algorithm ซึ่งเป็นกระบวนการหรือขั้นตอน เพื่อใช้แก้ปัญหาใดปัญหาหนึ่งและนำไปทำงานบนควอนตัมคอมพิวเตอร์ โดยใช้ความสามารถของ Quantum Superposition หรือ Quantum entanglement โดยรูปแบบที่ใช้โดยทั่วไปจะใช้วงจรควอนตัมเป็น โมเดลการคำนวณ สิ่งที่น่าสนใจของอัลกอริทึมควอนตัมคือมีโอกาสที่จะสามารถแก้ปัญหาที่คอมพิวเตอร์คลาสสิกไม่สามารถแก้ได้ โดยใช้เวลาที่เป็นไปได้หรือเวลาที่จำกัด แม้จะใช้ Supercomputer ที่ใหญ่ที่สุดก็ตาม โดยเราเรียกสิ่งนี้ว่า Quantum supremacy อัลกอริทึมที่เป็นที่รู้จักเป็นอย่างดีคือ Shor's algorithm [2] ที่ใช้สำหรับแก้ปัญหา Integer factorization หรือ Prime decomposition และ Grover's algorithm [3] ที่ใช้สำหรับการทำ Unstructured search algorithm หรือ Brute-force searching ด้วยการให้หลักการ Amplitude amplification

2.3 อัลกอริทึมควอนตัมแบบเปลี่ยนแปลง (Variational quantum algorithm)

ควอนตัมคอมพิวเตอร์ในยุคปัจจุบันยังมีคุณภาพที่ไม่ดีนักเพราะมีทั้งสัญญาณรบกวนและมีข้อผิดพลาดในการคำนวณอยู่ (NISQ Devices) จึงยังไม่สามารถที่จะนำไปใช้งานกับอัลกอริทึมที่มีความซับซ้อนมากหรือมีระยะเวลาในการทำงานที่นานได้ จึงเกิดแนวคิด Variational quantum algorithms ที่พยายามศึกษาและหาวิธีการที่จะสามารถใช้งานควอนตัมคอมพิวเตอร์ที่

มีควิบิตที่ยังไม่เสถียรนี้ โดยวิธีการคือใช้งานควอนตัมคอมพิวเตอร์ควบคู่ไปกับคอมพิวเตอร์คลาสสิกโดยจะทำงานเป็นรอบซ้ำ ๆ (Iteration) เพื่อให้ควอนตัมคอมพิวเตอร์นั้นทำงานในระยะเวลาสั้น ๆ โดยจะแบ่งออกเป็น 2 ส่วนคือ ส่วนของการคำนวณด้วยวงจรควอนตัมแบบฝึกได้ (Trainable quantum circuits) และส่วนของการเพิ่มประสิทธิภาพ (Optimization) ด้วยคอมพิวเตอร์คลาสสิก ในแต่ละรอบคอมพิวเตอร์คลาสสิกจะส่งชุดของพารามิเตอร์ θ (Parameter) ไปให้กับวงจรควอนตัมแบบฝึกได้ ในวงจรจะมีควอนตัมเกตที่สามารถปรับค่าตามได้และทำการคำนวณผลลัพธ์ออกมา หลังจากนั้นจะส่งผลลัพธ์ที่คำนวณได้กลับไปให้คอมพิวเตอร์คลาสสิกเพื่อทำการเพิ่มประสิทธิภาพด้วยการหาค่าพารามิเตอร์ชุดใหม่เพื่อที่จะให้ได้ค่า Error (Cost function) ที่ต่ำหรือสูงที่สุด โดยอัลกอริทึมที่มีชื่อเสียงที่น่าแนวคิดนี้ไปใช้คือ Variational Quantum Eigensolver (VQE) [4] และ Quantum Approximate Optimization Algorithm (QAOA)[5]

2.4 ปัญหาการถดถอย (Regression problems)

ปัญหาการถดถอยเป็นปัญหาที่ใช้วิธีการในการหาความสัมพันธ์ระหว่างตัวแปรต้นเพื่อใช้ในการพยากรณ์ค่าของตัวแปรเป้าหมายในเชิงประมาณ การวิเคราะห์ปัญหาการถดถอยนั้นถูกนำมาใช้อย่างแพร่หลายและเป็นวงกว้างไม่ว่าจะเป็นในอุตสาหกรรม การเงิน ธนาคาร สุขภาพ ฯลฯ ตัวอย่างของปัญหาการถดถอยเช่น การพยากรณ์ยอดขายของสินค้าในบริษัท หรือการพยากรณ์ราคาหุ้นในตลาดหลักทรัพย์ หรือการพยากรณ์จำนวนผู้ติดเชื้อโควิด ในการวัดค่าผลลัพธ์ของการทำนายหรือพยากรณ์ค่าของตัวแปรเป้าหมายนั้นจะใช้การวัดค่าความผิดพลาดหรือค่าความคลาดเคลื่อน เช่นการหารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error: RMSE) เป็นต้น

2.5 งานวิจัยที่เกี่ยวข้อง

ในปี 1997 หลังจาก Peter Shor ได้นำเสนอ Shor's algorithm [2] ที่สามารถแสดงให้เห็นว่าคอมพิวเตอร์ควอนตัมนั้นสามารถคำนวณในสิ่งที่คอมพิวเตอร์คลาสสิกไม่สามารถทำได้ จึงเป็นจุดกำเนิดให้นักวิจัยเริ่มสนใจความเป็นไปได้ในการใช้งานควอนตัมคอมพิวเตอร์และเกิดอัลกอริทึมควอนตัมใหม่ ๆ ออกมามากมายเพื่อนำไปแก้ปัญหาล่าง ๆ และยังนำไปสู่ โมเดลการเรียนรู้ของเครื่องแบบควอนตัม (Quantum machine learning) ที่นำความสามารถของควอนตัมมาช่วยในการเพิ่มประสิทธิภาพของการเรียนรู้ของเครื่องอีกด้วย

2.5.1 โมเดลการเรียนรู้ของเครื่องแบบควอนตัม (Quantum machine learning)

โมเดลการเรียนรู้ของเครื่องแบบควอนตัมเป็นหนึ่งในสิ่งที่จะได้รับความนิยมและมีแนวโน้มที่ควอนตัมคอมพิวเตอร์จะเข้ามาช่วยพัฒนาความสามารถในการสร้างโมเดลการเรียนรู้ของเครื่อง ใน [6] [7] [8] ได้แสดงให้เห็นว่าด้วยความสามารถในการคำนวณแบบ Matrix operations และ Linear algebraic operations ในควอนตัมคอมพิวเตอร์ที่ทำได้ดีกว่า อัลกอริทึมที่เรามีบนคอมพิวเตอร์คลาสสิก เมื่อเรานำอัลกอริทึมควอนตัมเช่น Quantum phase estimation algorithm, Grover's search, qBLAS มาเป็นพื้นฐานของโมเดลการเรียนรู้ของเครื่องแบบควอนตัมจึงทำให้เกิด Quantum principal component analysis (Quantum PCA), Quantum support vector machines and kernel methods (Quantum SVM) ทำให้เกิด Quantum speedup ที่ดีกว่า โมเดลการเรียนรู้ของเครื่องแบบคลาสสิก

2.5.2 อัลกอริทึมควอนตัมแบบเปลี่ยนแปลง (Variational Quantum Algorithm)

ถึงแม้ว่าอัลกอริทึมควอนตัมต่าง ๆ ที่ถูกคิดขึ้นมานั้นจะมีแนวโน้มที่แสดงให้มีความสามารถที่ดีกว่าวิธีการแบบคลาสสิก แต่ในปัจจุบันนั้นควอนตัมคอมพิวเตอร์อยู่ในยุคที่เรียกว่า Noisy Intermediate-Scale Quantum (NISQ) technology ที่นิยามโดย John Preskill [9] ซึ่งยังมีขนาดที่ยังไม่ใหญ่มาก มีจำนวนคิวบิตประมาณ 50-100 คิวบิต และยังมีสัญญาณรบกวนอยู่ เพราะเนื่องจากเรายังไม่สามารถควบคุมคิวบิตได้ดีพอและด้วยคุณลักษณะจากกลศาสตร์ควอนตัมที่เราต้องการนำมาใช้นั้น การที่จะทำให้เกิดสิ่งเหล่านี้ได้เราจำเป็นต้องจัดการให้ระบบหรือคิวบิตของเราแยกออกจากสิ่งอื่นหรือโลกภายนอกอย่างสมบูรณ์และยังต้องให้คิวบิตนั้นทำปฏิริยาต่อกันเพื่อให้เกิด Quantum Entanglement ระหว่างคิวบิต

ด้วยข้อจำกัดและสัญญาณรบกวนที่กล่าวมานี้ทำให้เกิดข้อจำกัดของการนำควอนตัมคอมพิวเตอร์ไปใช้งาน Kishor Bhati และคณะ [10] ได้รวบรวมและวิเคราะห์ข้อจำกัดและข้อได้เปรียบ เช่น ไม่สามารถให้คิวบิตทำงานกับวงจรควอนตัมที่มีจำนวนควอนตัมเกตที่มีจำนวนเยอะได้ เพราะสัญญาณรบกวนจะทำให้การคำนวณผิดพลาด ดังนั้นเมื่อจะออกแบบอัลกอริทึมควอนตัมหรือนำควอนตัมคอมพิวเตอร์ในยุคปัจจุบันไปใช้จึงควรคำนึงถึงข้อจำกัดเรื่องสัญญาณรบกวนและขนาดของวงจรควอนตัม

ในปัจจุบันนักวิจัยได้ออกแบบอัลกอริทึมควอนตัมที่เรียกว่า Variational Quantum Algorithm (VQAs) [11] ที่พัฒนามาจาก Variational eigenvalue solver (VQE) [4] ที่สามารถทำงานได้ดีบน NISQ device เพราะตัวอัลกอริทึมนี้ใช้การทำงานแบบวนรอบ

และใช้ควอนตัมคอมพิวเตอร์ควบคู่ไปกับคลาสสิกคอมพิวเตอร์ ทำให้การคำนวณที่ต้องใช้ควอนตัมคอมพิวเตอร์นั้นมีระยะเวลาสั้น ๆ และใช้จำนวนคิวบิตที่ไม่เยอะมาก โดยมี Quantum Approximate Optimization Algorithm (QAOA) [5] เป็นอัลกอริทึมที่เป็นที่รู้จัก และสามารถใช้งานได้ดีสามารถนำไปใช้แก้ปัญหาประเภท Combinatorial optimization problems ได้

2.5.3 วงจรควอนตัมแบบปรับค่าได้มาเป็น โมเดลการเรียนรู้ (Parameterized quantum circuits as machine learning)

Marcello Benedetti และคณะ [12] และ Yuxuan Du และคณะ [13] ได้รวบรวมเปรียบเทียบและนำเสนอการนำวงจรควอนตัมแบบปรับค่าได้มาเป็น โมเดลการเรียนรู้ Maria Schuld [14] [15] ได้นำเสนอ Circuit-centric quantum classifiers เพื่อใช้ในการทำการเรียนรู้แบบมีผู้สอน (Supervised Learning) ด้วยการใช้เทคนิคที่เรียกว่า Low-depth variational quantum algorithm ในการสอนโมเดลการเรียนรู้ของเครื่อง โดยจะเป็นการทำงานแบบไฮบริดที่ทำงานร่วมกันระหว่างควอนตัมคอมพิวเตอร์และคอมพิวเตอร์คลาสสิก (Hybrid quantum-classical gradient descent) และมีจุดเด่นคือการใช้จำนวน Learnable parameters หรือจำนวน parametrized gate ที่ใช้น้อยกว่าอัลกอริทึมอื่น กล่าวคือ จำนวนพารามิเตอร์โตด้วยอัตรา Poly-logarithmic ต่อจำนวนข้อมูลเข้า (Input dimension) จึงทำให้วงจรควอนตัมมีขนาดเล็กและสามารถทำงานได้ดีใน NISQ device

2.5.4 ควอนตัมโครงข่ายประสาทเทียม (Quantum neural networks)

จากความสามารถในการสร้างโมเดลการเรียนรู้ของเครื่องจากวงจรควอนตัมแบบปรับค่าได้ Amira Abbas [16] ได้นำเสนอและเปรียบเทียบความสามารถของ Quantum Neural network model กับ Classical feedforward neural networks ในด้านของ Model Capacity และ Trainability โดยจะแบ่งควอนตัมโครงข่ายประสาทเทียมออกเป็น 2 โมเดล คือ Easy quantum model ที่สามารถจำลองด้วยคอมพิวเตอร์คลาสสิกได้ง่ายและ Quantum Neural network model ที่ใช้ Quantum Feature map ที่นำเสนอโดย Vojtech Havlicek และคณะ [17] ที่เป็นการทำ Data encoding strategy ที่ใช้ความสามารถของกลศาสตร์ควอนตัมที่ยากต่อการจำลองด้วยคอมพิวเตอร์คลาสสิกเพื่อที่จะทดสอบว่าการทำ Data encoding จะส่งผลต่อโมเดลการเรียนรู้มากน้อยเพียงใด

ในงานวิจัยนี้ทำโดยนักวิจัยจากทีม IBM Quantum ซึ่งเป็นทีมที่พัฒนาและสร้าง

ควอนตัมคอมพิวเตอร์ของตัวเองจึงทำให้สามารถทดสอบและเก็บผลลัพธ์จากเครื่องควอนตัมคอมพิวเตอร์จริงที่มีอยู่ในปัจจุบัน (ibmq montreal 27-qubit device) ซึ่งเป็นสิ่งที่ค่อนข้างยากสำหรับนักวิจัยภายนอกที่จะทดสอบได้ถึงแม้ว่าควอนตัมคอมพิวเตอร์ของ IBM จะเปิดให้บุคคลภายนอกใช้งานได้ผ่าน Cloud computing ก็ตาม

ผลลัพธ์ที่ได้จากงานวิจัยนี้แสดงให้เห็นว่าโมเดลควอนตัมโครงข่ายประสาทเทียม นั้นมีความสามารถที่เหนือกว่าโครงข่ายประสาทเทียมแบบคลาสสิกทั้งในแง่ของ Model Capacity ที่ดีกว่า และความเร็วของ Trainability ที่ดีกว่า และความสามารถของ Quantum Feature map ที่ชี้ให้เห็นว่า Data encoding มีผลต่อความสามารถของโมเดล โดยการใช้ Higher order feature map จะสามารถแก้ปัญหา barren plateau ได้ อีกทั้งยังส่งผลต่อ Model Capacity และ Trainability อีกด้วย

ในงานวิจัยของเรานั้นจะนำวิธีการสร้างวงจรควอนตัมแบบปรับค่าได้และรูปแบบของ โครงสร้างควอนตัม โครงข่ายประสาทเทียม รวมทั้งการใช้ Higher order feature map เพื่อแปลง ข้อมูลแบบคลาสสิกให้เป็นสถานะทางควอนตัม โดยปัญหาที่เราจะแก้จะเป็นการนำควอนตัม โครงข่ายประสาทเทียมไปใช้กับการปัญหาการถดถอยเพื่อทำนายจำนวน โทเคนที่ต้องใช้ในการ ลงทะเบียนเรียนด้วยข้อมูลจากระบบประมวลผลรายวิชาของภาควิชาวิศวกรรมคอมพิวเตอร์คณะ วิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย [18] และใช้ในการทำนายจำนวนผู้ติดเชื้อ โควิด 2019 ในประเทศไทย

บทที่ 3

วิธีดำเนินการวิจัย

ในงานวิจัยนี้เราจะมุ่งความสนใจไปที่การสร้างโมเดลควอนตัมโครงข่ายประสาทด้วยการใช้เครื่องมือจำลองควอนตัมคอมพิวเตอร์จาก Qiskit และในส่วนของ การสอน โมเดลจะแบ่งออกเป็น 3 ส่วน คือ Data Encoding, Quantum Neural network model, Model training and Optimization

3.1 ข้อมูลที่ใช้ในการศึกษา (Training Data)

3.1.1 ข้อมูลจากระบบประมวลวิชาตั้งแต่ปี 2015 จนถึง 2019

ข้อมูลชุดแรกที่ใช้ในการทดลองนี้จะนำมาจากระบบประมวลรายวิชาดังแสดงตัวอย่างในภาพที่ 1 และเนื่องจากการจำลองควอนตัมคอมพิวเตอร์ด้วยคอมพิวเตอร์คลาสสิกนั้นทำได้ยากและต้องใช้ทรัพยากรที่สูงเป็นเอกโปกเนนเชียลต่อจำนวนคิวบิตที่ต้องการใช้หรือความลึกของวงจรควอนตัม ดังนั้นด้วยข้อจำกัดนี้เราจึงจำกัดจำนวนคิวบิตไว้ที่ 4 คิวบิต นั้นหมายความว่าข้อมูลเข้าที่ใช้ในการสอนโมเดลการเรียนรู้นั้นจะต้องเลือกจากข้อมูลที่สำคัญที่สุดหรือมีค่า Correlation score ดังแสดงในภาพที่ 2 สูงที่สุด 4 ค่า จากการเลือกข้อมูลนำเข้าที่มีความสำคัญที่สุดจึงได้ข้อมูลนำเข้า 4 ตัว แสดงในตารางที่ 1 และข้อมูลที่ใช้จะถูกกรองจากข้อมูลที่มี course interesting ที่มากกว่า 2 เพื่อลดเวลาในการสอน

3.1.2 ข้อมูลรายงานผู้ติดเชื้อโควิด 2019 ในประเทศไทย

ข้อมูลชุดที่สองเป็นข้อมูลรายงานผู้ติดเชื้อโควิด 2019 จะใช้ข้อมูล 4 วันย้อนหลังในการทำนายจำนวนผู้ติดเชื้อในวันต่อไป โดยจะใช้ข้อมูลจากวันที่ 1 เมษายน 2564 จนถึง วันที่ 19 ธันวาคม 2564 ดังแสดงในภาพที่ 3

ตารางที่ 1 ตัวอย่างชุดตัวแปรนำเข้าและตัวแปรเป้าหมายสำหรับข้อมูลชุดที่ 1 จากระบบประมวลรายวิชา


Input	output
course interesting	Token price
all_mean	
enrolled_min	
enrolled_mean	

	Student_Id	Course_Id	Course_name_x	Year	Limit	Token	Enrolled	Regstatus	Refund	Forcerrefund
0	55 xxxxxxxx	444	COMP SECURITY	2015	40	260001	1	11	0	0
1	53 xxxxxxxx	444	COMP SECURITY	2015	40	50000	0	20	1	0
2	55 xxxxxxxx	444	COMP SECURITY	2015	40	260000	1	11	0	0
3	56 xxxxxxxx	444	COMP SECURITY	2015	40	270000	1	11	0	0
4	55 xxxxxxxx	444	COMP SECURITY	2015	40	302991	1	11	0	0

ภาพที่ 1 ตัวอย่างข้อมูลจากระบบประมวลรายวิชา

	all_max	all_min	all_mean	enrolled_max	enrolled_min	enrolled_mean	unenrolled_max	unenrolled_min	unenrolled_mean	Token
all_max	1.00	0.14	0.78	0.97	0.57	0.76	0.68	0.24	0.51	0.65
all_min	0.14	1.00	0.15	0.14	0.28	0.14	0.12	-0.01	0.06	0.12
all_mean	0.78	0.15	1.00	0.80	0.80	0.97	0.70	0.01	0.43	0.84
enrolled_max	0.97	0.14	0.80	1.00	0.60	0.78	0.59	-0.00	0.31	0.68
enrolled_min	0.57	0.28	0.80	0.60	1.00	0.88	0.63	-0.08	0.37	0.76
enrolled_mean	0.76	0.14	0.97	0.78	0.88	1.00	0.70	-0.05	0.39	0.86
unenrolled_max	0.68	0.12	0.70	0.59	0.63	0.70	1.00	0.39	0.72	0.60
unenrolled_min	0.24	-0.01	0.01	-0.00	-0.08	-0.05	0.39	1.00	0.87	-0.04
unenrolled_mean	0.51	0.06	0.43	0.31	0.37	0.39	0.72	0.87	1.00	0.34
Token	0.65	0.12	0.84	0.68	0.76	0.86	0.60	-0.04	0.34	1.00

ภาพที่ 2 Correlation Matrix ของข้อมูลจากระบบประมวลรายวิชา



ภาพที่ 3 กราฟแสดงข้อมูลชุดที่ 2 ข้อมูลผู้ติดเชื้อ โควิด 2019 ในประเทศไทย

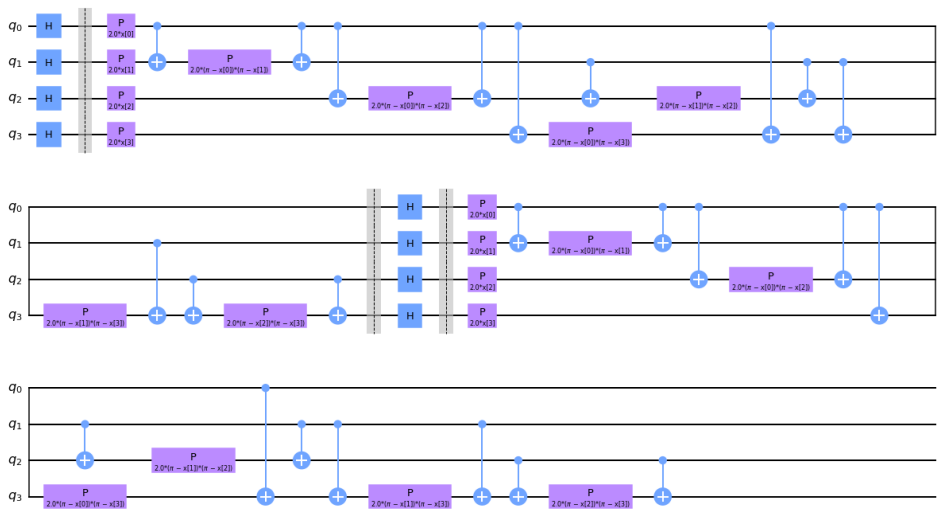
	txn_date	new_case
0	2021-04-01	26
1	2021-04-02	58
2	2021-04-03	84
3	2021-04-04	96

ภาพที่ 4 ตัวอย่างข้อมูลผู้ติดเชื้อโควิด 2019 ในแต่ละวัน

3.2 การเข้ารหัสข้อมูล (Data Encoding)

การใช้ควอนตัมคอมพิวเตอร์ในการคำนวณนั้นจำเป็นที่จะต้องแปลงข้อมูลแบบคลาสสิก (Classical data) ให้เป็นสถานะทางควอนตัม (Quantum state) ก่อนที่จะนำไปใช้งานหรือนำเข้ากระบวนการเรียนรู้ ในขั้นตอนนี้เราจะทำการแปลงให้ข้อมูลให้เป็นสถานะทางควอนตัมด้วยการใช้ Second-order Pauli-z evolution circuit หรือ (ZZFeature map) ที่พัฒนาขึ้นจาก [17] โดยกำหนดให้มีจำนวน 4 คิวบิต และมี 2 วงจรซ้ำ

ตัววงจรจะเริ่มด้วยการใช้ Hadamard gate บนทุก ๆ คิวบิต และตามด้วย RZ-gates เพื่อเข้ารหัสข้อมูลและใช้ CNOT-gates บนทุก ๆ คู่ของคิวบิต เพื่อให้เกิด Full entanglement โดยผลลัพธ์ที่ได้จากวงจรนี้จะนำไปใช้เป็นข้อมูลเข้าให้กับโมเดลควอนตัมโครงข่ายประสาทเทียมต่อไป โดยรูปแบบวงจร ZZFeatureMap circuit แสดงในภาพที่ 5




ภาพที่ 5 วงจร Second-order Pauli-Z evolution circuit (ZZFeatureMap)

3.3 โมเดลควอนตัมโครงข่ายประสาทเทียม (Quantum Neural network model)

สำหรับวงจรควอนตัมที่ใช้เป็นโมเดลนั้นจะใช้ Real Amplitudes variational circuit เป็นโครงสร้างของโครงข่ายประสาทเทียมตัววงจรจะประกอบด้วย 4 คิวบิต และใช้ชั้นของ RY-gates ที่เป็นควอนตัมเกตแบบปรับค่าได้กับทุก ๆ คิวบิต และใช้ CNOT-gate บนทุก ๆ คู่ของคิวบิตเพื่อให้เกิด Full entanglement โดยเราจะทำวงจรซ้ำ หรือเพิ่มความลึกของวงจร เพื่อเพิ่มจำนวนควอนตัมเกตแบบปรับค่าได้ให้กับโมเดล ซึ่งตัวควอนตัมเกตแบบปรับค่าได้นี้จะเป็นเหมือนค่าน้ำหนักของโครงข่ายประสาทเทียม (Neural Network weights) ในโครงข่ายประสาทเทียมแบบคลาสสิกนั่นเอง โดยจำนวนตัวแปรที่สามารถสอนได้ (Trainable parameter) นั้นสามารถคำนวณได้จากสูตร

$$d = (D + 1)S$$

โดย S คือจำนวนข้อมูลเข้า (Input size) และ D คือจำนวนวงจรทำซ้ำหรือความลึกของวงจร ตัวอย่างของ Real Amplitudes circuit ที่มีความลึกเท่ากับ 2 โดยวงจรจะประกอบด้วยชั้นของ RY-gate ตามด้วย CNOT-gates บนทุก ๆ คู่ของคิวบิต ในวงจรนี้จะมีควอนตัมเกตแบบปรับค่าได้ทั้งหมด 12 ตัว แสดงในภาพที่ 6



ภาพที่ 6 วงจร RealAmplitudes circuit ที่มี 2 วงจรซ้ำ

3.4 การสอนโมเดลและการเพิ่มประสิทธิภาพ (Model training and Optimization)


ในข้อมูลชุดที่ 1 จากระบบประมวลรายวิชาจะทดลองปรับค่าความลึกหรือจำนวนวงจรซ้ำเพื่อหาโครงสร้างของโมเดลที่ดีที่สุดโดยจะทำการสอนโมเดลด้วยไฮเปอร์พารามิเตอร์ 2 ชุดคือ

3.4.1 500 iterations ในความลึกของวงจรตั้งแต่ 2-5 ชั้นและใช้ ADAM Optimizer ที่มี learning rate 0.001

3.4.2 100 iterations ในความลึกของวงจรตั้งแต่ 4-7 ชั้น และใช้ ADAM Optimizer ที่มี learning rate 0.1 เพื่อลดเวลาในการสอนสำหรับวงจรที่มีขนาดใหญ่

และในข้อมูลชุดที่ 2 จากข้อมูลรายงานผู้ติดเชื้อ Covid-19 จะทำการสอนด้วยโมเดลไฮเปอร์พารามิเตอร์ 100 iterations ในความลึกของวงจรตั้งแต่ 2-9 ชั้น และใช้ ADAM Optimizer ที่มี learning rate 0.1 เพื่อลดเวลาในการสอนสำหรับวงจรที่มีขนาดใหญ่

สำหรับ Loss function จะใช้ Mean squared error (MSE) เพื่อสามารถเปรียบเทียบกับงานวิจัยเรื่องการประเมินการจัดสรรโทเคนสำหรับการประมวลวิชาด้วยการเรียนรู้ของเครื่อง [18] โดยภาพรวมของขั้นตอนการสอนทั้งหมดแสดงใน ภาพที่ 7 จะมีขั้นตอนการทำ Feature map และวงจรควอนตัมที่ทำงานบนควอนตัมคอมพิวเตอร์และจะส่งผลลัพธ์กลับไปเพื่อปรับปรุงเพิ่มประสิทธิภาพบนคอมพิวเตอร์แบบคลาสสิก



ภาพที่ 7 ภาพรวมของกระบวนการสอน โมเดลควอนตัม โครงข่ายประสาทเทียม

3.5 การแบ่งข้อมูลชุดสำหรับการสอนและชุดทดสอบ (Train-Test data split)

เนื่องจากเวลาที่ใช้ในการสอน โมเดลการเรียนรู้ของเครื่องแบบควอนตัมในแต่ละรอบนั้นใช้เวลานานจึงไม่สามารถทำการตรวจสอบไขว้ (K-Fold cross validation) ได้ ในงานวิจัยนี้จึงเลือกใช้วิธี Hold-out

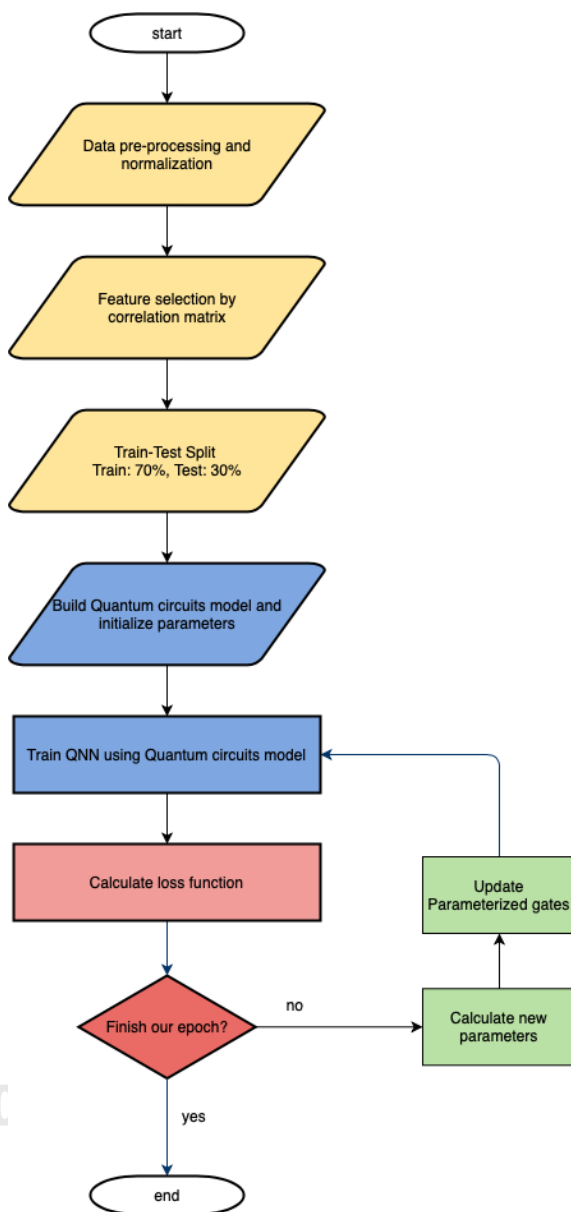
โดยในข้อมูลชุดที่ 1 จากระบบประมวลรายวิชาจะแบ่งข้อมูลออกเป็นข้อมูลสำหรับการสอน 70% และข้อมูลสำหรับทดสอบ 30% และในข้อมูลชุดที่ 2 จากรายงานผู้ติดเชื้อโควิด 2019 ในประเทศไทย จะแบ่งข้อมูลเป็นช่วงเวลา โดยข้อมูลตั้งแต่วันที่ 1 เมษายน 2021 จนถึง วันที่ 21 สิงหาคม 2021 จะเป็นข้อมูลสำหรับการฝึกสอน และข้อมูลตั้งแต่วันที่ 22 สิงหาคม 2021 จนถึง วันที่ 19 ธันวาคม 2021 จะเป็นข้อมูลสำหรับการทดสอบ

3.6 การประเมินผล (Model Evaluation)

สำหรับข้อมูลจากระบบประมวลรายวิชาจะใช้ค่า RMSE ในการวัดผลประสิทธิภาพของโมเดล เพื่อสามารถเปรียบเทียบกับงานวิจัยเรื่องการประเมินการจัดสรรโทเคนสำหรับการประมวลวิชา ด้วยการเรียนรู้ของเครื่อง [18] และสำหรับข้อมูลรายงานผู้ติดเชื้อโควิด 2019 จะใช้ ค่า RMSE และค่า R-Squared ในการวัดผล และเปรียบเทียบกับผลการทดสอบด้วยโมเดลโครงข่ายประสาทเทียมแบบคลาสสิก

3.7 กระบวนการสอน (Training process)

แผนผังแสดงขั้นตอนการสอน โมเดลการเรียนรู้ของเครื่องแสดงในภาพที่ 8



ภาพที่ 8 แผนภาพแสดงขั้นตอนการสอนโมเดลควอนตัมโครงข่ายประสาทเทียม

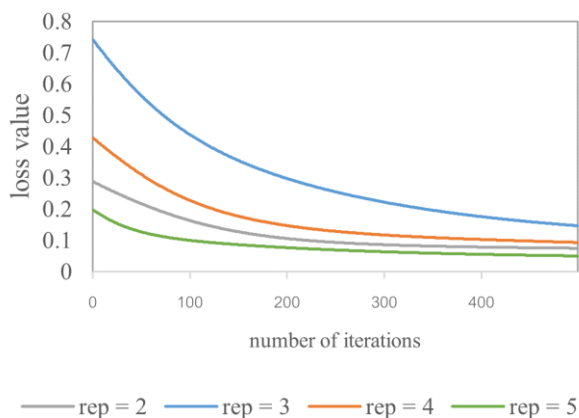
บทที่ 4

ผลการวิจัย


4.1 ผลการวิจัยการทำนายการจัดสรรโทเคนในระบบประมวลรายวิชา

4.1.1 ผลการสอนโมเดลการเรียนรู้ของเครื่อง

ทดสอบสร้างโมเดลควอนตัมโครงข่ายประสาทเทียมและทำการสอน โมเดลการเรียนรู้ของเครื่องบนข้อมูลชุดข้อมูลฝึกสอนจาก 70% ของข้อมูลทั้งหมด โดยมีการปรับไฮเปอร์พารามิเตอร์ ชุดที่ 1 ด้วย ความลึกของวงจรควอนตัมที่ความลึกจาก 2-5 ชั้น และใช้ ADAM Optimizer ที่มี learning rate 0.001 และ ไฮเปอร์พารามิเตอร์ ชุดที่ 2 ด้วย ความลึกของวงจรควอนตัมที่ความลึกจาก 4-7 ชั้น และใช้ ADAM Optimizer ที่มี learning rate 0.1 โดยแสดงผลการสอนโมเดลด้วย Loss value ในแผนภาพที่ 9 และ 10 แสดงให้เห็นว่าความลึกของวงจรควอนตัมที่ความลึก 5 ชั้น มีค่า loss value ที่ต่ำที่สุด



ภาพที่ 9 ผลการสอน โมเดลจากข้อมูลชุดที่ 1 ด้วยไฮเปอร์พารามิเตอร์ชุดที่ 1



ภาพที่ 10 ผลการสอน โมเดลจากข้อมูลชุดที่ 1 ด้วยไฮเปอร์พารามิเตอร์ชุดที่ 2

4.1.2 ผลการใช้ชุดทดสอบ (Test Dataset)

การทดลองนี้ใช้การวัดผลการทำนายด้วยชุดข้อมูลทดสอบด้วยการวัดค่า RMSE แสดงในตารางที่ 2 โดยผลการทำนายของโมเดลควอนตัมโครงข่ายประสาทเทียมนั้นแสดงให้เห็นว่าการเพิ่มความลึกของวงจรจาก 2-5 ชั้น ทำให้ผลการทำนายดีขึ้น ค่า RMSE นั้นลดลง แต่การเพิ่มความลึกของวงจรเป็น 6-7 ชั้น แสดงให้เห็นว่าโมเดลมีความสามารถในการทำนายที่ไม่ต่างจากวงจร 5 ชั้น

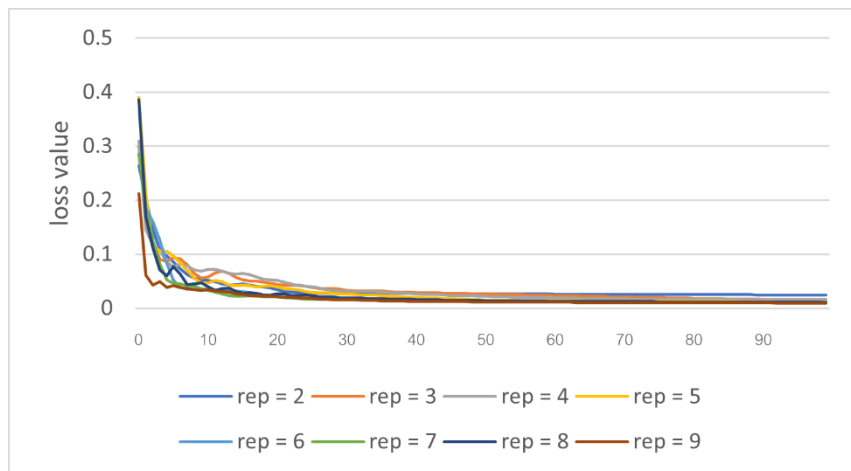
ตารางที่ 2 ผลการใช้ชุดทดสอบจากข้อมูลการประเมินการจัดสรรโทเคนสำหรับการประมวลวิชา

Number of repeated circuits	Number of trainable gates	RMSE	
		$lr = 0.001$	$lr = 0.1$
2	12	0.0952	-
3	16	0.1198	-
4	20	0.1097	0.0691
5	24	0.0780	0.0638
6	28		0.0632
7	32		0.0633

4.2 ผลการวิจัยการทำนายจำนวนผู้ติดเชื้อโควิด 2019 ในวันถัดไป โดยใช้ข้อมูล 4 วันก่อนหน้า

4.2.1 ผลการสอนโมเดลการเรียนรู้ของเครื่อง

ทดสอบสร้างโมเดลโครงข่ายประสาทเทียมและทำการสอนโมเดลการเรียนรู้ของเครื่องโดยใช้ไฮเปอร์พารามิเตอร์ที่ปรับความลึกของวงจรควอนตัมที่ความลึกจาก 2-9 ชั้น และใช้ ADAM Optimizer ที่มี learning rate 0.1 โดยค่า Loss value ขณะสอนโมเดลการเรียนรู้นั้นเบนเข้าหาจุดต่ำสุด ค่า Loss value แสดงในแผนภาพที่ 11



ภาพที่ 11 ผลการสอนโมเดลจากข้อมูลชุดที่ 2

4.2.2 ผลการใช้ชุดทดสอบ (Test Dataset)

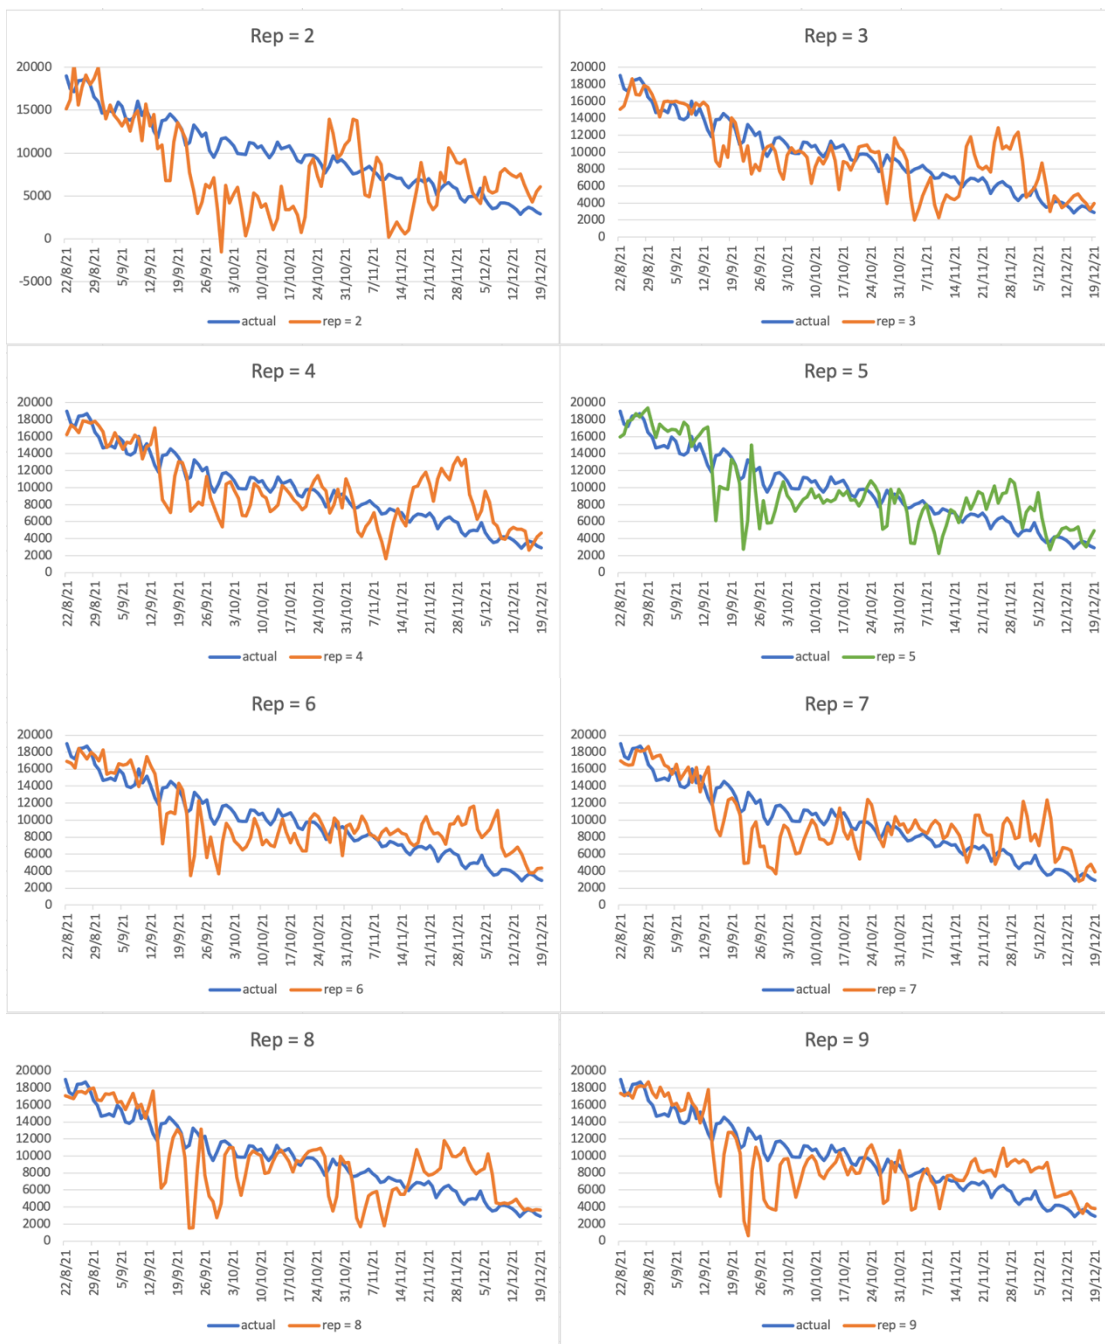
การทดลองนี้ใช้การวัดผลการทำนายด้วยชุดข้อมูลทดสอบด้วยการวัดค่า RMSE และ R-Squared แสดงในตารางที่ 3 และผลการทดสอบดังภาพที่ 12 โดยใช้ข้อมูลช่วงเวลาตั้งแต่วันที่ 22 สิงหาคม 2021 จนถึงวันที่ 19 ธันวาคม 2021 ผลการทำนายของโมเดลควอนตัมโครงข่ายประสาทเทียมนั้นแสดงให้เห็นว่าความลึกของวงจร 5 ชั้นให้ผลการทำนายดีที่สุด มีค่า RMSE ต่ำที่สุดที่ 2695.8751 และค่า R-Squared สูงที่สุดที่ 0.57146618 โดยจะใช้ผลการทำนายด้วยโมเดลโครงข่ายประสาทเทียมแบบคลาสสิก แสดงในตารางที่ 4 เพื่อเปรียบเทียบ โมเดลที่ดีที่สุดมีจำนวนชั้นซ่อน (Hidden Layer) 2 ชั้น มีค่า RMSE ต่ำที่สุดที่ 1081.3613 และค่า R-Squared ที่ 0.9310511170113531 ทำให้เห็นว่าโมเดลควอนตัมโครงข่ายประสาทเทียมยังมีความสามารถที่ไม่ดีในการทำนายชุดข้อมูลนี้เมื่อเทียบกับ โมเดลโครงข่ายประสาทเทียมแบบคลาสสิก

ตารางที่ 3 ผลการใช้ชุดทดสอบจากข้อมูลผู้ป่วยโควิด 2019 ในประเทศไทยด้วยโมเดลควอนตัมโครงข่ายประสาทเทียม

Number of repeated circuits	Number of trainable gates	RMSE	R2
2	12	4475.5121	-0.1810575
3	16	2760.7542	0.55059174
4	20	3012.8651	0.46476449
5	24	2695.8751	0.57146618
6	28	2928.4238	0.49434603
7	32	2962.2228	0.48260647
8	36	3249.8226	0.37726274
9	40	3105.0765	0.43150038

ตารางที่ 4 ผลการใช้ชุดข้อมูลทดสอบจากข้อมูลผู้ป่วยโควิด 2019 ในประเทศไทยด้วยโมเดลโครงข่ายประสาทเทียมแบบคลาสสิก

Number of hidden layers	RMSE	R2
2	1081.3613	0.9310511170113531
3	1178.5064	0.9181065021445597
4	1314.1483	0.8981703409634584
5	1324.9035	0.8964967357021784
6	1263.2755	0.9059017187724461
7	1093.7310	0.9294646872510898
8	1197.0925	0.9155030538856681
9	1248.8682	0.9080358080565516



ภาพที่ 12 ผลการทำนายข้อมูลผู้ป่วยโควิด 2019 ในประเทศไทยด้วยโมเดลควอนตัมโครงข่ายประสาทเทียม

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

ในงานวิจัยนี้ผลลัพธ์แสดงให้เห็นว่าโมเดลควอนตัมโครงข่ายประสาทเทียมสามารถใช้ในการสอนให้โมเดลการเรียนรู้ของเครื่องได้และสามารถนำไปใช้ในการแก้ไขปัญหาประเภทการถดถอย (Regression problem) โดยใช้ข้อมูลจากโลกจริงได้และมีผลการทำนายที่ดีเมื่อเปรียบเทียบกับโมเดลโครงข่ายประสาทเทียมแบบคลาสสิก โมเดลในงานวิจัยนี้ถูกจำกัดด้วยขนาดของข้อมูลเข้าที่ 4 ตัว เนื่องจากเวลาที่ใช้ในการสอนโมเดลการเรียนรู้นั้นใช้เวลาค่อนข้างมากประมาณ 4-12 ชั่วโมงโดยขึ้นอยู่กับความลึกของวงจรในการสอน 100 รอบ

จากผลการวิจัยพบว่าเมื่อนำโมเดลไปใช้ในการทำนายข้อมูลจริง โดยในข้อมูลชุดที่ 1 จากระบบประมวลผลรายวิชาเพื่อทำนายจำนวนโทเคนที่จำเป็นสำหรับการลงทะเบียนในแต่ละวิชา โมเดลที่มีความลึกของวงจรที่ 5 ชั้นให้ผลลัพธ์การทำนายที่ดีที่สุด โดยมีค่า RMSE ที่ 6.38% เปรียบเทียบกับผลการทำนายด้วย ANN จากงานวิจัย [18] ที่ใช้จำนวนข้อมูลเข้า 8 ตัว มีค่า RMSE ที่ 3.98% และในข้อมูลชุดที่ 2 ข้อมูลจำนวนผู้ติดเชื้อโควิด 2019 ในประเทศไทย เพื่อทำนายจำนวนผู้ติดเชื้อในวันต่อไปด้วยข้อมูลผู้ติดเชื้อ 4 วันย้อนหลัง โมเดลที่ดีที่สุดมีความลึกของวงจรที่ 5 ชั้นให้ผลลัพธ์การทำนายที่มี RMSE ต่ำที่สุดที่ 2695.8751 และค่า R-Squared ที่ 0.57146618 เมื่อเปรียบเทียบกับโมเดลโครงข่ายประสาทเทียมแบบคลาสสิก โมเดลที่ดีที่สุดมีจำนวนชั้นซ่อน 2 ชั้น มีค่า RMSE ต่ำที่สุดที่ 1081.3613 และค่า R-Squared ที่ 0.9310511170113531 ทำให้เห็นว่าโมเดลควอนตัมโครงข่ายประสาทเทียมยังมีความสามารถที่ไม่ดีในการทำนายจำนวนผู้ติดเชื้อโควิด 2019 ในประเทศไทย

ในส่วนของการสร้างโมเดลการเรียนรู้การเพิ่มความลึกของวงจร หรือการเพิ่มจำนวน RY-gate มีความคล้ายกับการเพิ่มจำนวนค่าน้ำหนักในโมเดลโครงข่ายประสาทเทียมแบบคลาสสิก โดยการเพิ่มจำนวนความลึกหรือจำนวน RY-gate ไม่เพียงแต่เพิ่มความสามารถของโมเดลแต่ยังช่วยลดค่า loss value และลดค่าความผิดพลาด (Error) ในการนำโมเดลไปใช้ทำนายผลอีกด้วย

วงจรควอนตัมแบบปรับค่าที่มีความลึกของวงจรที่ไม่มากนักสามารถนำมาใช้จริงบนเครื่องควอนตัมคอมพิวเตอร์ในยุคปัจจุบันที่เป็นแบบ NISQ ได้ และได้แสดงให้เห็นถึงความสามารถ

ที่จะนำควอนตัมคอมพิวเตอร์มาใช้ในการเรียนรู้ของเครื่องได้ดี

5.2 ข้อเสนอแนะ

ในงานวิจัยนี้มีข้อจำกัดที่จำนวนคิวบิตและการจำลองผลด้วยการใช้ Simulator เท่านั้น โดยในอนาคต IBM จะเปิดให้ผู้ใช้ภายนอกสามารถที่จะใช้เครื่องควอนตัมคอมพิวเตอร์ประมวลผลโปรแกรมในรูปแบบของควอนตัมอัลกอริทึมแบบแปรผัน (VQA) ได้ดีขึ้นด้วย IBM Qiskit Runtime ทำให้มีโอกาสที่จะสอนโมเดลการเรียนรู้ของเครื่องได้ดีขึ้นและใช้เครื่องคอมพิวเตอร์ควอนตัมจริง และในงานวิจัยในอนาคตสามารถปรับปรุงขั้นตอนการสอนและขั้นตอนการสร้างวงจรสำหรับการเข้ารหัสข้อมูล (Feature map circuit) วงจรสำหรับเป็นโมเดลการเรียนรู้ได้หลากหลายรูปแบบมากกว่าในปัจจุบันรวมทั้งการปรับรูปแบบของการัวพันเชิงควอนตัม



บรรณานุกรม

- [1] M. A. Nielsen and I. L. Chuang, *Quantum Computation and Quantum Information: 10th Anniversary Edition*. Cambridge University Press, 2010.
- [2] P. W. Shor, "Polynomial-Time Algorithms for Prime Factorization and Discrete Logarithms on a Quantum Computer," *SIAM Journal on Computing*, vol. 26, no. 5, pp. 1484-1509, 1997. [Online]. Available: <https://doi.org/10.1137/S0097539795293172>.
- [3] L. K. Grover, "Quantum Mechanics Helps in Searching for a Needle in a Haystack," *Phys. Rev. Lett.*, vol. 79, pp. 325-328, Jul 1997. [Online]. Available: <https://link.aps.org/doi/10.1103/PhysRevLett.79.325>.
- [4] A. Peruzzo *et al.*, "A variational eigenvalue solver on a photonic quantum processor," *Nature Communications*, vol. 5, no. 1, Jul 2014. [Online]. Available: <http://dx.doi.org/10.1038/ncomms5213>.
- [5] E. Farhi, J. Goldstone, and S. Gutmann, "A Quantum Approximate Optimization Algorithm," ed, 2014.
- [6] J. Biamonte, P. Wittek, N. Pancotti, P. Rebentrost, N. Wiebe, and S. Lloyd, "Quantum machine learning," *Nature*, vol. 549, no. 7671, pp. 195–202, Sep 2017. [Online]. Available: <http://dx.doi.org/10.1038/nature23474>.
- [7] C. Ciliberto *et al.*, "Quantum machine learning: a classical perspective," *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 474, no. 2209, p. 20170551, Jan 2018. [Online]. Available: <http://dx.doi.org/10.1098/rspa.2017.0551>.
- [8] V. Dunjko and H. J. Briegel, "Machine learning & artificial intelligence in the quantum domain," ed, 2017.
- [9] J. Preskill, "Quantum Computing in the NISQ era and beyond," *Quantum*, vol. 2, p. 79, Aug 2018. [Online]. Available: <http://dx.doi.org/10.22331/q-2018-08-06-79>.
- [10] K. Bharti *et al.*, "Noisy intermediate-scale quantum (NISQ) algorithms," ed, 2021.
- [11] M. Cerezo *et al.*, "Variational Quantum Algorithms," ed, 2020.
- [12] M. Benedetti, E. Lloyd, S. Sack, and M. Fiorentini, "Parameterized quantum

- circuits as machine learning models," *Quantum Science and Technology*, vol. 4, no. 4, p. 043001, Nov 2019. [Online]. Available: <http://dx.doi.org/10.1088/2058-9565/ab4eb5>.
- [13] Y. Du, M.-H. Hsieh, T. Liu, and D. Tao, "Expressive power of parametrized quantum circuits," *Physical Review Research*, vol. 2, no. 3, Jul 2020. [Online]. Available: <http://dx.doi.org/10.1103/PhysRevResearch.2.033125>.
- [14] M. Schuld, I. Sinayskiy, and F. Petruccione, "The quest for a Quantum Neural Network," *Quantum Information Processing*, vol. 13, no. 11, pp. 2567–2586, Aug 2014. [Online]. Available: <http://dx.doi.org/10.1007/s11128-014-0809-8>.
- [15] M. Schuld, A. Bocharov, K. M. Svore, and N. Wiebe, "Circuit-centric quantum classifiers," *Physical Review A*, vol. 101, no. 3, Mar 2020. [Online]. Available: <http://dx.doi.org/10.1103/PhysRevA.101.032308>.
- [16] A. Abbas, D. Sutter, C. Zoufal, A. Lucchi, A. Figalli, and S. Woerner, "The power of quantum neural networks," *Nature Computational Science*, vol. 1, no. 6, pp. 403–409, Jun 2021. [Online]. Available: <http://dx.doi.org/10.1038/s43588-021-00084-1>.
- [17] V. Havlíček *et al.*, "Supervised learning with quantum-enhanced feature spaces," *Nature*, vol. 567, no. 7747, pp. 209–212, Mar 2019. [Online]. Available: <http://dx.doi.org/10.1038/s41586-019-0980-2>.
- [18] C. Juthamane, K. Piromsopa, and P. Chongstitvatana, "Token Allocation for Course Bidding With Machine Learning Method," in *2021 18th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, 19-22 May 2021 2021, pp. 1168-1171, doi: 10.1109/ECTI-CON51831.2021.9454670.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	Suraphan Laokondee
วัน เดือน ปี เกิด	11 May 1991
สถานที่เกิด	Bangkok, Thailand
วุฒิการศึกษา	KING MONGKUT'S UNIVERSITY OF TECHNOLOGY NORTH BANGKOK
ที่อยู่ปัจจุบัน	45/54 Bangsrimueng Nonthaburi 11000
ผลงานตีพิมพ์	Laokondee, S. and Chongstitvatana, P., "Quantum neural network model for token allocation for course bidding." Int. Computer Science and Engineering Conference, 18-20 Nov, 2021, Thailand.