

TESIS

**DESAIN HYBRID QUANTUM CONVOLUTIONAL NEURAL
NETWORKS (QCNN) DALAM PENINGKATAN
PERFORMANCE PADA KLASIFIKASI CITRA**



STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

Oleh :

Supardi Atisina

23206051024

PROGRAM STUDI INFORMATIKA
PROGRAM MAGISTER FAKULTAS SAINS DAN TEKNOLOGI
UIN SUNAN KALIJAGA

YOGYAKARTA

2025

PERNYATAAN KEASLIAN

PERNYATAAN KEASLIAN

Yang bertanda tangan di bawah ini :

Nama : Supardi Atisina
NIM : 23206051024
Jenjang : Magister
Program Studi : Informatika

menyatakan bahwa naskah tesis ini secara keseluruhan adalah hasil penelitian/karya saya sendiri, kecuali pada bagian-bagian yang dirujuk sumbernya.

Yogyakarta, 10 Juli 2025

Saya yang menyatakan,



Supardi Atisina

NIM : 23206051024

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

PERNYATAAN BEBAS PLAGIASI

PERNYATAAN BEBAS PLAGIASI

Yang bertanda tangan di bawah ini :

Nama : Supardi Atisina
NIM : 23206051024
Jenjang : Magister
Program Studi : Informatika

menyatakan bahwa naskah tesis ini secara keseluruhan benar-benar bebas dari plagiasi. Jika di kemudian hari terbukti melakukan plagiasi, maka saya siap ditindak sesuai ketentuan hukum yang berlaku

Yogyakarta, 10 Juli 2025

Saya yang menyatakan,



Supardi Atisina

AAAMX362424866

Supardi Atisina

NIM : 23206051024

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

HALAMAN PENGESAHAN



KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN KALIJAGA
FAKULTAS SAINS DAN TEKNOLOGI
Jl. Marsda Adisucipto Telp. (0274) 540971 Fax. (0274) 519739 Yogyakarta 55281

PENGESAHAN TUGAS AKHIR

Nomor : B-1433/Un.02/DST/PP.00.9/07/2025

Tugas Akhir dengan judul : Desain Hybrid Quantum Convolutional Neural Network (QCNN) dalam Peningkatan Performance pada Klasifikasi Citra

yang dipersiapkan dan disusun oleh:

Nama : SUPARDI ATISINA, S.T
Nomor Induk Mahasiswa : 23206051024
Telah diujikan pada : Senin, 14 Juli 2025
Nilai ujian Tugas Akhir : A

dinyatakan telah diterima oleh Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta

TIM UJIAN TUGAS AKHIR



Valid ID: 68805ad594d98

Ketua Sidang

Prof. Dr. Ir. Shofwatul 'Uyun, S.T., M.Kom., IPM., ASEAN Eng.
SIGNED



Valid ID: 687df590c7ee2

Penguji I

Ir. Maria Ulfah Siregar, S.Kom., MIT., Ph.D.
SIGNED



Valid ID: 687f6d7ed9c7d

Penguji II

Muhammad Mustakim, S.T. M.T.
SIGNED



Valid ID: 688068b52686

Yogyakarta, 14 Juli 2025
UIN Sunan Kalijaga
Dekan Fakultas Sains dan Teknologi

Prof. Dr. Dra. Hj. Khurul Wardati, M.Si.
SIGNED

NOTA DINAS PEMBIMBING

NOTA DINAS PEMBIMBING

Kepada Yth.,
Dekan Fakultas Sains dan Teknologi
UIN Sunan Kalijaga
Yogyakarta

Assalamu 'alaikum wr. wb.

Setelah melakukan bimbingan, arahan, dan koreksi terhadap penulisan tesis yang berjudul:

DESAIN HYBRID QUANTUM CONVOLUTIONAL NEURAL NETWORKS (QCNN) DALAM PENINGKATAN PERFORMANCE PADA KLASIFIKASI CITRA

Yang ditulis oleh:

Nama : Supardi Atisina
NIM : 23206051024
Jenjang : Magister
Program Studi : Informatika

Saya berpendapat bahwa tesis tersebut sudah dapat diajukan kepada Magister Informatika UIN Sunan Kalijaga untuk diujikan dalam rangka memperoleh gelar Magister Informatika.

Wassalamu'alaikum wr. wb.

Yogyakarta, 10 Juli 2025
Pembimbing,



Prof. Dr. Ir. Shofwatul 'Uyun, S.T.,
M.Kom., IPM., ASEAN Eng.
NIP : 19820511 200604 2 002

ABSTRAK

Jaringan Saraf Konvolusional (CNN) sebagai standar dalam klasifikasi citra menghadapi tantangan fundamental, termasuk kebutuhan parameter dalam jumlah besar yang boros secara komputasi serta keterbatasan dalam menangkap korelasi data non-lokal. Sebagai paradigma alternatif, Quantum Convolutional Neural Networks (QCNN) secara teoretis menawarkan solusi melalui kapasitas representasinya yang lebih tinggi dengan arsitektur yang lebih efisien. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi secara kuantitatif sebuah model QCNN hibrida, serta membandingkan kinerjanya secara komprehensif terhadap arsitektur CNN klasik.

Metode penelitian ini menggunakan pendekatan eksperimental pada dataset MNIST 3 kelas yang direduksi menjadi resolusi 4x4 piksel. Model QCNN hibrida dirancang menggunakan TensorFlow Quantum dengan arsitektur 16 data qubit, 3 readout qubit, dan interaksi tipe-Ising untuk ekstraksi fitur. Hasil eksperimen menunjukkan bahwa QCNN mencapai akurasi superior sebesar 70.67%, secara signifikan melampaui model CNN (~49% akurasi). Selain itu, QCNN terbukti 41% lebih efisien dari segi jumlah parameter (108 vs 183), meskipun dengan tantangan komputasi yang signifikan pada simulator klasik.

Disimpulkan bahwa arsitektur QCNN hibrida memiliki potensi signifikan untuk meningkatkan akurasi dan efisiensi model dibandingkan arsitektur CNN sederhana, yang memvalidasi keunggulan teoretisnya untuk tugas ini. Tantangan komputasi yang muncul akibat simulasi menekankan pentingnya pengembangan di masa depan. Oleh karena itu, penelitian selanjutnya direkomendasikan untuk fokus pada pengujian model pada dataset yang lebih kompleks serta implementasi pada perangkat keras kuantum nyata untuk validasi performa di dunia nyata.

Kata Kunci: Quantum Convolutional Neural Networks (QCNN), Quantum Machine Learning (QML), Klasifikasi Citra, Komputasi Kuantum, Convolutional Neural Network (CNN).

ABSTRACT

Convolutional Neural Networks (CNNs), the standard in image classification, face fundamental challenges including a large parameter requirement which is computationally expensive, and limitations in capturing non-local data correlations. As an alternative paradigm, Quantum Convolutional Neural Networks (QCNNs) theoretically offer a solution through higher representational capacity with a more efficient architecture. This research aims to implement and quantitatively evaluate a hybrid QCNN model, and to comprehensively compare its performance against classical CNN architectures.

This research employed an experimental method on a 3-class MNIST dataset reduced to a 4x4 pixel resolution. The hybrid QCNN model was designed using TensorFlow Quantum with a 16 data-qubit and 3 readout-qubit architecture, utilizing Ising-type interactions for feature extraction. Experimental results show that the QCNN achieved a superior accuracy of 70.67%, significantly outperforming the CNN models (~49% accuracy). Furthermore, the QCNN proved to be 41% more parameter-efficient (108 vs. 183), albeit with a significant computational challenge on the classical simulator.

It is concluded that the hybrid QCNN architecture has significant potential to improve classification accuracy and model efficiency compared to simple CNN architectures for this task, thus validating its theoretical advantages. The computational challenges arising from simulation underscore the importance of future quantum hardware development. Therefore, future research is recommended to focus on testing the model on more complex datasets and implementing it on real quantum hardware for real-world performance validation.

Keywords: *Quantum Convolutional Neural Networks (QCNN), Quantum Machine Learning (QML), Image Classification, Quantum Computing, Convolutional Neural Networks (CNN).*

MOTTO

“Tak ada yang benar-benar peduli dengan hidupmu—
hingga kamu membuktikan bahwa kamu bisa berhasil.
Semua orang punya peluang untuk mencapai apa pun,
tergantung seberapa kuat dan tangguh mereka
menjalannya. Jadi, berhentilah terlalu banyak mengeluh
atau terlalu cepat merasa bangga. Di luar sana, akan
selalu ada yang lebih sukses atau lebih gagal darimu,
lebih sempurna atau lebih terluka. Namun pada akhirnya,
semuanya akan terasa cukup jika kamu mampu bersyukur
atas apa yang sudah kamu miliki.”

--Supardi Atisina

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Puji syukur *Alhamdulillahirabbil'alamin* penulis panjatkan ke hadirat Allah SWT atas limpahan rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan tesis ini yang berjudul “**Desain Hybrid Quantum Convolutional Neural Networks (QCNN) dalam Peningkatan Performance pada Klasifikasi Citra**” sebagai salah satu syarat untuk memperoleh gelar Magister pada Program Studi Magister Informatika di UIN Sunan Kalijaga Yogyakarta.

Tesis ini membahas implementasi *Quantum Convolutional Neural Networks* (QCNN) sebagai pendekatan inovatif dalam meningkatkan performa sistem klasifikasi citra. Penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan ilmu pengetahuan, khususnya di bidang *quantum machine learning* dan *computer vision*.

Penyusunan tesis ini tentunya tidak lepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, dengan segala hormat dan ketulusan, penulis menyampaikan terima kasih dan penghargaan yang sebesar-besarnya kepada:

1. Prof. Noorhaidi Hasan, S.Ag., MA., M.Phil., Ph.D., selaku Rektor UIN Sunan Kalijaga Yogyakarta.
2. Prof. Dr. Dra. Hj. Khurul Wardati, M.Si., selaku Dekan Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta.
3. Dr. Ir. Sumarsono, S.T., M.Kom., selaku Kaprodi Program Studi Magister Informatika, Fakultas Sains dan Teknologi, UIN Sunan Kalijaga Yogyakarta.

4. Prof. Dr. Ir. Shofwatul 'Uyun, S.T., M.Kom., IPM., ASEAN Eng., selaku dosen pembimbing tesis atas bimbingan, arahan, kesabaran, dan motivasi yang telah diberikan selama proses penyusunan tesis ini. Bimbingan beliau sangat berarti dalam mengarahkan penulis hingga tesis ini dapat terselesaikan dengan baik.
5. Ir. Muhammad Taufiq Nuruzzaman, S.T., M.Eng., Ph.D., selaku dosen pembimbing akademik yang telah membimbing selama proses studi yang kurang lebih 2 tahun.
6. Seluruh dosen dan staf pengajar di Fakultas Sains dan Teknologi, UIN Sunan Kalijaga Yogyakarta, yang telah memberikan ilmu dan wawasan selama masa studi.
7. Lembaga Pengelola Dana Pendidikan (LPDP) dan Kementerian Agama Republik Indonesia (Kemenag RI) atas dukungan finansial melalui program beasiswa santri berprestasi (PBSB), yang memungkinkan penulis menempuh pendidikan magister ini dengan optimal.
8. Kedua orang tua yaitu papa Sardin Atisina dan mama Rusna Malaingan yang menjadi motivasi paling besar saya untuk menyelesaikan studi ini, serta saudara kandung saya yang tercinta, atas doa, kasih sayang, dan semangat yang senantiasa menyertai langkah penulis.
9. Rekan-rekan seperjuangan dan sahabat selama proses studi yaitu Zishwa Muhammad Jauhar Nafis, Riki Riyandi, Rega Nugraha, Muh. Nur Aslam, Muhammad Fahson Hakim, Annida Rizki Luthfi Astuti dan Rahmatun Nazila yang selalu memberikan semangat, tawa, dan dukungan moril selama masa studi dan penyusunan tesis

ini. Kebersamaan dan solidaritas kalian menjadi bagian yang tak terlupakan dalam perjalanan studi ini.

10. Secara khusus, penulis juga mengucapkan terima kasih kepada Hijriyah, yang telah menjadi sumber semangat dan ketenangan hati meskipun harus menjalani hubungan jarak jauh (LDR). Dukungan dan pengertianmu menjadi bagian penting dalam proses ini.

Penulis menyadari bahwa karya ini masih memiliki keterbatasan. Oleh karena itu, kritik dan saran yang membangun sangat penulis harapkan demi perbaikan ke depan. Semoga tesis ini dapat memberikan manfaat dan menjadi pijakan untuk penelitian selanjutnya dalam bidang yang sama.

Wassalamu'alaikum Warahmatullahi Wabarakatuh

Yogyakarta, 10 Juli 2025

Penulis



Supardi Atisina

NIM : 23206051024

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

DAFTAR ISI

TESIS.....	I
PERNYATAAN KEASLIAN	II
PERNYATAAN BEBAS PLAGIASI.....	III
HALAMAN PENGESAHAN	IV
NOTA DINAS PEMBIMBING	V
ABSTRAK.....	VI
<i>ABSTRACT</i>	VII
MOTTO.....	VIII
KATA PENGANTAR	IX
DAFTAR ISI	XII
DAFTAR TABEL	XV
DAFTAR GAMBAR	XVI
DAFTAR SINGKATAN	XVII
DAFTAR ISTILAH.....	XVIII
BAB I PENDAHULUAN	1
A. Latar Belakang	1
B. Rumusan Masalah.....	4
C. Batasan Masalah.....	5
D. Tujuan Penelitian	5
E. Manfaat Penelitian	6
1. Kontribusi Teoritis	6
2. Kontribusi Praktis.....	6
BAB II KAJIAN PUSTAKA DAN LANDASAN TEORI.....	8
A. Kajian Pustaka	8
B. Landasan Teori.....	12
1. Klasifikasi Citra.....	12

2.	<i>Convolutional Neural Network (CNN)</i>	12
3.	Prinsip Dasar Komputasi Kuantum	14
4.	Gerbang Kuantum	15
5.	<i>Quantum Machine Learning (QML)</i>	18
6.	Evaluasi Model Klasifikasi	19
BAB III METODE PENELITIAN		26
A.	Kerangka Penelitian	26
B.	Lingkungan Komputasi dan Perangkat Lunak	27
C.	Dataset dan Pra-Pemrosesan Data	28
1.	Penyaringan Kelas	28
2.	Reduksi Dimensi	28
2.	Pengambilan Sampel	30
3.	Pembersihan Data	30
4.	Normalisasi	30
D.	Desain dan Arsitektur Model	30
1.	Hybrid QCNN	30
2.	CNN Klasik (<i>Baseline</i>)	32
3.	CNN Optimasi	33
E.	Prosedur Pelatihan dan Evaluasi	34
BAB IV HASIL DAN PEMBAHASAN		35
A.	Validasi Hasil Melalui Kode	35
1.	Load dan Normalisasi dataset	35
2.	Penyaringan kelas dan Reduksi dimensi	36
3.	Pengambilan Sampel	36
4.	Penghapusan Sampel Ambigu (<i>Data Cleaning</i>)	37
5.	Arsitektur Sirkuit Kuantum Tervariasi (<i>Ansatz</i>)	39
6.	Pembangunan Model Hibrida Kuantum-Klasik	40
7.	Pelaksanaan Pelatihan Model Hibrida	41
B.	Hasil	42
1.	Ringkasan Metrik Performa Kuantitatif	42
2.	Analisis Matriks Konfusi	46
3.	Analisis Kurva Pembelajaran (<i>Learning Curve</i>)	49
C.	Pembahasan	52

1. Keunggulan Performa Klasifikasi	52
2. Efisiensi Arsitektur dan Tantangan Komputasi	54
BAB V PENUTUP	57
A. Kesimpulan	57
1. Implementasi Model QCNN Hibrida	57
2. QCNN Menunjukkan Peningkatan Performa.....	57
B. Saran.....	58
1. Analisis Sensitivitas Hiperparameter	58
2. Penerapan Dataset Lebih Kompleks dan Besar.....	59
3. Implementasi Perangkat Keras Kuantum Nyata	59
4. Eksplorasi Arsitektur Hibrida Alternatif.....	59
DAFTAR PUSTAKA	61
DAFTAR RIWAYAT HIDUP	64



DAFTAR TABEL

No. Tabel	Halaman
2.1 Tabel Kajian Pustaka	10
3.1. Ringkasan Arsitektur CNN Klasik	33
3.2. Ringkasan Arsitektur CNN Optimasi	33
4.1. Perbandingan Metrik Performa Model pada Data Uji	42



DAFTAR GAMBAR

Gambar 1	Kerangka Penelitian	27
Gambar 2	Visualisasi Dataset untuk digit 0, 1 dan 2.	28
Gambar 3	Visualisasi Dataset untuk digit 0, 1 dan 2 yang sudah di Resize	29
Gambar 4	Visualisasi Sirkuit Angle Encoding untuk Satu Sampel Citra	31
Gambar 5	Script untuk Load dataset dan Normalisasi	35
Gambar 6	Penyaringan Kelas dan Reduksi Dimensi	36
Gambar 7	Pengambilan Sampel	36
Gambar 8	Penghapusan Sampel Ambigu	37
Gambar 9	Pengkodean Data Klasik ke Kuantum	38
Gambar 10	Pembangunan Model Hibrida	40
Gambar 11	Pelatihan Model	41
Gambar 12	Matrix Konfusi	46
Gambar 13	Perbandingan Kurva Akurasi dan Loss Selama Pelatihan	50

STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

DAFTAR SINGKATAN

Bit	: <i>Binary Digit</i>
CNN	: <i>Convolutional Neural Network</i>
DL	: <i>Deep Learning</i>
NISQ	: <i>Noisy Intermediate-Scale Quantum</i>
Qubit	: <i>Quantum Bit</i>
QML	: <i>Quantum Machine Learning</i>
QCNN	: <i>Quantum Convolutional Neural Network</i>
ReLU	: <i>Rectified Linear Unit</i>
TFQ	: <i>TensorFlow Quantum</i>
TPU	: <i>Tensor Processing Unit</i>



STATE ISLAMIC UNIVERSITY
SUNAN KALIJAGA
YOGYAKARTA

DAFTAR ISTILAH

- Bit** : Unit terkecil dalam penyimpanan dan pemrosesan data di komputer. Digunakan menyimpan data semua jenis informasi (teks, gambar, suara) dikonversi ke dalam bentuk biner (0 dan 1).
- Dense** : Lapisan pada neural network di mana setiap neuron terhubung ke semua neuron di lapisan sebelumnya, digunakan untuk proses klasifikasi akhir.
- Entanglement** : Fenomena kuantum saat dua atau lebih qubit saling terhubung sehingga keadaan salah satu langsung memengaruhi yang lain, meskipun terpisah jarak jauh.
- Flatten** : Operasi yang mengubah output dari lapisan konvolusi atau pooling menjadi vektor satu dimensi (1D).
- Overfitting** : Model belajar terlalu detail dari data latih hingga tidak bekerja baik pada data baru.
- Pooling** : Teknik untuk merangkum informasi dengan mengecilkan ukuran data, biasanya mengambil nilai tertinggi atau rata-rata.
- Qubit** : Unit dasar informasi dalam komputasi kuantum, mirip seperti bit dalam komputasi klasik. Bit klasik hanya bisa berada dalam keadaan 0 ATAU 1. Qubit bisa berada dalam keadaan 0, 1, atau superposisi dari keduanya secara bersamaan.
- ReLU** : Fungsi aktivasi yang digunakan dalam CNN untuk menambahkan non-linearitas pada jaringan, artinya mengubah nilai jika inputnya positif maka outputnya akan tetap, tetapi jika inputnya negatif maka di ganti dengan nol.
- Superposisi** : Kondisi qubit berada di antara 0 dan 1 sekaligus, bukan hanya salah satunya.
- Stride** : Jumlah langkah pergeseran filter saat melakukan konvolusi.
- Tipe-Ising** : Interaksi antar qubit dalam model kuantum yang meniru sifat magnet di fisika.

BAB I

PENDAHULUAN

A. Latar Belakang

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence* - AI) dalam beberapa dekade terakhir telah membawa perubahan fundamental di berbagai sektor, mulai dari industri, kesehatan, hingga sains dan teknologi. Salah satu cabang AI yang paling berpengaruh adalah *Machine Learning* (ML), dan di dalamnya, *Deep Learning* (DL) telah menunjukkan kapabilitas yang luar biasa, terutama dalam tugas-tugas yang melibatkan data tidak terstruktur seperti citra, suara, dan teks (Goodfellow, Bengio and Courville, 2016).

Dalam domain visi komputer (*computer vision*), *Convolutional Neural Network* (CNN) telah menjadi standar emas untuk tugas klasifikasi citra (Lecun *et al.*, 1998). Arsitektur CNN, yang terinspirasi dari korteks visual biologis, mampu secara otomatis dan adaptif mempelajari hierarki fitur dari sebuah citra, mulai dari tepi dan tekstur sederhana hingga objek yang kompleks. Keberhasilan CNN terbukti dalam berbagai aplikasi krusial, seperti diagnosis medis melalui citra radiologi (Esteva *et al.*, 2017), sistem kendaraan otonom (Bojarski *et al.*, 2016), dan pengenalan wajah untuk keamanan (Parkhi, Vedaldi and Zisserman, 2015).

Meskipun CNN klasik sangat dominan, arsitektur ini mulai menghadapi tantangan fundamental. Seiring dengan meningkatnya kompleksitas masalah dan resolusi citra, model CNN yang diperlukan menjadi semakin dalam dan besar. Hal ini membawa beberapa konsekuensi diantaranya adalah beban komputasi yang masif karena

melatih model *deep learning* yang sangat dalam (seperti ResNet-152 atau DenseNet) memerlukan sumber daya komputasi yang sangat besar, termasuk GPU (*Graphics Processing Unit*) berperforma tinggi dan waktu pelatihan yang bisa mencapai berhari-hari atau bahkan berminggu-minggu (He *et al.*, 2015; Simonyan and Zisserman, 2015). Selain itu adanya juga kebutuhan data yang sangat besar guna untuk menghindari *overfitting* dan mencapai generalisasi yang baik, model-model ini membutuhkan jutaan data citra berlabel, yang pengumpulannya bisa jadi mahal dan sulit (Sun *et al.*, 2017). Permasalahan lain yaitu adanya keterbatasan representasi fitur dengan adanya indikasi bahwa model klasik, terlepas dari kedalamannya, mungkin memiliki keterbatasan dalam merepresentasikan korelasi data yang sangat kompleks dan non-lokal yang secara inheren ada dalam beberapa tipe data (Pérez-Salinas *et al.*, 2020).

Di tengah tantangan ini, paradigma komputasi baru yang revolusioner mulai muncul dengan hadirnya komputasi kuantum. Komputasi kuantum ini berlandaskan pada prinsip-prinsip mekanika kuantum seperti superposisi, keterkaitan (*entanglement*), dan interferensi, komputasi kuantum menjanjikan kekuatan pemrosesan eksponensial untuk kelas masalah tertentu yang tidak dapat ditangani oleh komputer klasik (Nielsen and Chuang, 2010). Potensi ini memicu lahirnya bidang *Quantum Machine Learning* (QML), yang bertujuan untuk memanfaatkan fenomena kuantum guna merancang algoritma pembelajaran yang lebih kuat dan efisien (Biamonte *et al.*, 2017; Xu *et al.*, 2023).

Salah satu proposal paling menarik dalam QML adalah *Quantum Convolutional Neural Network* (QCNN). QCNN adalah analogi

kuantum dari CNN klasik, yang dirancang untuk bekerja pada data kuantum maupun data klasik yang telah dikodekan ke dalam keadaan kuantum (Cong, Choi and Lukin, 2019). Arsitektur QCNN menggunakan sirkuit kuantum tervariasi (*variational quantum circuits*) untuk menjalankan operasi yang serupa dengan lapisan konvolusi dan pooling pada CNN klasik. Keunggulannya terletak pada kemampuannya untuk beroperasi dalam ruang Hilbert yang berdimensi eksponensial, yang secara teoritis memungkinkan QCNN untuk menangkap pola dan korelasi data yang rumit dengan jumlah parameter yang jauh lebih sedikit dibandingkan model klasik (Henderson *et al.*, 2020).

Model yang diusulkan dalam penelitian ini secara spesifik adalah model QCNN hibrida. Pendekatan hibrida, yang mengintegrasikan komputasi klasik dan kuantum, dianggap sebagai strategi paling praktis di era *Noisy Intermediate-Scale Quantum* (NISQ) saat ini (McClean *et al.*, 2016; Preskill, 2018). Dalam arsitektur hibrida ini, tugas-tugas seperti pra-pemrosesan citra dan optimisasi parameter sirkuit kuantum ditangani oleh komputer klasik, sementara ekstraksi fitur inti dilakukan oleh prosesor kuantum. Secara khusus, penelitian ini akan mengadopsi interaksi tipe-Ising dalam desain sirkuit kuantumnya. Interaksi tipe-Ising, yang terinspirasi dari model fisika statistik, sangat efektif dalam menciptakan keterkaitan (*entanglement*) antar-qubit, yang dihipotesiskan krusial untuk mengekstraksi fitur-fitur kompleks dari data citra (Schuld and Petruccione, 2021).

Meskipun QCNN menunjukkan potensi teoritis yang besar, penelitian di bidang ini masih dalam tahap awal. Banyak implementasi yang masih terbatas pada dataset sederhana (seperti MNIST) dan dijalankan pada simulator kuantum. Terdapat celah pengetahuan yang

signifikan mengenai bagaimana performa QCNN, khususnya dengan arsitektur hibrida dan interaksi spesifik, jika dibandingkan secara langsung dengan arsitektur CNN klasik yang canggih pada tugas klasifikasi citra multi-kelas.

Oleh karena itu, penelitian ini bertujuan untuk mengisi celah tersebut dengan melakukan implementasi, analisis, dan evaluasi mendalam terhadap model QCNN hibrida. Penelitian ini akan berfokus pada kuantifikasi "peningkatan performa" yang dapat ditawarkan oleh QCNN, tidak hanya dari segi akurasi klasifikasi, tetapi juga dari aspek lain seperti jumlah parameter dan potensi efisiensi komputasi. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi nyata bagi pemahaman komunitas ilmiah mengenai kelayakan dan potensi praktis dari QCNN sebagai generasi penerus model visi komputer.

B. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka permasalahan utama dalam penelitian ini dapat dirumuskan dalam beberapa pertanyaan berikut:

1. Bagaimana merancang dan mengimplementasikan sebuah arsitektur *Quantum Convolutional Neural Network* (QCNN) hibrida yang efektif untuk tugas klasifikasi citra multi-kelas?
2. Bagaimana perbandingan kinerja komprehensif antara model QCNN hibrida dan model CNN klasik, yang mencakup evaluasi metrik performa seperti akurasi, F1-Score, waktu inferensi dan lain lain serta efisiensi jumlah parameter?

C. Batasan Masalah

Agar penelitian ini lebih terfokus dan mendalam, ditetapkan beberapa batasan yang mendefinisikan cakupan penelitian sebagai berikut:

1. Studi ini tidak melakukan perbandingan dengan arsitektur kuantum lain seperti *Quantum Convolutional Neural Networks* (QCNN) atau model berbasis *quantum kernel*.
2. Penelitian ini tidak menguji model pada dataset yang lebih besar, lebih kompleks, atau dengan resolusi yang lebih tinggi seperti CIFAR-10 atau ImageNet.
3. Penelitian ini tidak melibatkan eksekusi atau pengujian pada perangkat keras kuantum nyata (real quantum hardware) karena keterbatasan akses dan tingkat noise pada perangkat era NISQ.
4. Fokus penelitian adalah pada implementasi dan evaluasi performa. Studi ini tidak mencakup perancangan algoritma kuantum baru dari dasar, pembahasan mendalam mengenai teori fundamental mekanika kuantum, atau rekayasa perangkat keras kuantum.

D. Tujuan Penelitian

Sejalan dengan rumusan masalah, maka tujuan dari penelitian ini adalah:

1. Mengimplementasikan sebuah model *Quantum Convolutional Neural Network* (QCNN) hibrida yang fungsional menggunakan *framework* perangkat lunak komputasi kuantum dan deep learning yang ada.
2. Mengevaluasi dan membandingkan secara komprehensif kinerja model QCNN hibrida terhadap model CNN klasik, yang mencakup

analisis kuantitatif metrik performa klasifikasi (seperti akurasi dan F1-Score) serta efisiensi arsitektur dari segi jumlah parameter.

E. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan kontribusi sebagai berikut:

1. Kontribusi Teoritis
 - a. Memberikan kontribusi pada khazanah ilmu pengetahuan di bidang *Quantum Machine Learning* (QML), khususnya pada sub-bidang QCNN.
 - b. Menyajikan studi kasus implementasi dan analisis performa yang terperinci untuk arsitektur QCNN hibrida, yang dapat menjadi referensi dan benchmark bagi para peneliti selanjutnya.
 - c. Memberikan wawasan empiris mengenai hubungan antara desain sirkuit kuantum (seperti penggunaan interaksi tipe-Ising) dengan kemampuan representasi fitur dalam konteks visi komputer.
2. Kontribusi Praktis
 - a. Menjadi bukti konsep (*proof-of-concept*) yang dapat mendorong pengembangan lebih lanjut model visi komputer berbasis kuantum yang lebih efisien di masa depan, ketika perangkat keras kuantum sudah lebih matang.
 - b. Menyediakan panduan implementasi praktis bagi para peneliti atau praktisi lain yang ingin mulai mengeksplorasi aplikasi QML untuk masalah klasifikasi citra.

- c. Secara jangka panjang, berpotensi membuka jalan bagi aplikasi di domain-domain di mana analisis pola yang sangat kompleks sangat krusial, seperti penemuan obat, ilmu material, atau citra satelit resolusi tinggi, yang mungkin melampaui kemampuan model klasik.



BAB V

PENUTUP

A. Kesimpulan

Berdasarkan implementasi, eksperimen, dan analisis komparatif yang telah dilakukan terhadap model QCNN hibrida, CNN Klasik, dan CNN Optimasi pada tugas klasifikasi 3 kelas dataset MNIST, maka dapat ditarik beberapa kesimpulan utama sebagai berikut:

1. Implementasi Model QCNN Hibrida

Penelitian ini telah berhasil merancang dan mengimplementasikan sebuah arsitektur QCNN hibrida yang fungsional untuk klasifikasi citra multi-kelas. Model ini, yang dibangun menggunakan platform TensorFlow Quantum, terbukti mampu dilatih dan menghasilkan prediksi yang dapat dievaluasi, sehingga tujuan penelitian pertama telah tercapai.

2. QCNN Menunjukkan Peningkatan Performa

Secara kuantitatif, model QCNN menunjukkan performa yang jauh lebih unggul dibandingkan kedua model CNN klasik. QCNN berhasil mencapai akurasi sebesar 70.67% dan F1-Score 68.18%. Angka ini secara signifikan melampaui performa CNN Klasik (akurasi 48.67%) dan CNN Optimasi (akurasi 49.33%). Analisis matriks konfusi juga mengungkap bahwa QCNN memiliki karakteristik pembelajaran yang berbeda, dengan keunggulan dalam mengenali kelas '1' yang justru menjadi kelemahan terbesar bagi model-model CNN. Hal ini mengindikasikan bahwa arsitektur kuantum dengan interaksi tipe-Ising

mampu menangkap fitur data yang lebih representatif, sehingga tujuan penelitian kedua telah terjawab dengan tuntas.

Secara keseluruhan, penelitian ini membuktikan bahwa arsitektur QCNN hibrida memiliki potensi signifikan untuk meningkatkan akurasi klasifikasi citra dan efisiensi model. Namun, keunggulan ini datang dengan tantangan komputasi yang besar pada tahap simulasi, yang perlu menjadi pertimbangan utama untuk implementasi praktis di masa depan.

B. Saran

Meskipun penelitian ini telah mencapai tujuannya, terdapat beberapa keterbatasan dan ruang untuk pengembangan lebih lanjut. Oleh karena itu, beberapa saran untuk penelitian selanjutnya adalah sebagai berikut:

1. Analisis Sensitivitas Hiperparameter

Penelitian ini menggunakan satu konfigurasi sirkuit kuantum yang tetap. Penelitian selanjutnya sangat disarankan untuk melakukan studi ablasi (*ablation study*) dengan memvariasikan hiperparameter sirkuit, seperti:

- a. Mengubah kedalaman sirkuit dengan menambah atau mengurangi lapisan entanglement (XX dan ZZ).
- b. Membandingkan efektivitas skema entanglement yang berbeda, misalnya antara interaksi tipe-Ising dengan gerbang CNOT.
- c. Mengeksplorasi dampak dari metode pengkodean data yang berbeda (misalnya, amplitude encoding).

2. Penerapan Dataset Lebih Kompleks dan Besar

Untuk menguji kemampuan generalisasi dan skalabilitas model QCNN, penelitian selanjutnya dapat menerapkannya pada dataset yang lebih menantang. Pengujian pada dataset seperti Fashion-MNIST, CIFAR-10, atau dataset citra medis dengan resolusi yang lebih tinggi akan memberikan validasi yang lebih kuat terhadap potensi praktis dari QCNN.

3. Implementasi Perangkat Keras Kuantum Nyata

Tantangan utama dalam penelitian ini adalah waktu inferensi yang lama akibat penggunaan simulator. Langkah selanjutnya yang krusial adalah mengimplementasikan dan menguji model ini pada perangkat keras kuantum nyata (misalnya, yang disediakan oleh IBM, Google, atau IonQ). Eksperimen ini akan memberikan wawasan berharga mengenai performa model di hadapan *noise* perangkat keras dan tantangan dalam teknik mitigasi eror (*error mitigation*).

4. Eksplorasi Arsitektur Hibrida Alternatif

Model dalam penelitian ini menggunakan PQC sebagai kepala klasifikasi (*classifier head*). Pendekatan arsitektur hibrida lain, seperti *Quantum Convolutional Neural Networks* (QCNN) di mana lapisan kuantum berfungsi sebagai filter untuk menghasilkan *feature maps* klasik, dapat dieksplorasi. Membandingkan berbagai pendekatan hibrida akan memperkaya pemahaman tentang cara terbaik mengintegrasikan kekuatan komputasi kuantum dan klasik.

Dengan menindaklanjuti saran-saran di atas, diharapkan pemahaman dan penerapan praktis dari *Quantum Convolutional Neural*

Networks dapat terus berkembang menuju realisasi potensinya secara penuh.



DAFTAR PUSTAKA

- Biamonte, J. *et al.* (2017) ‘Quantum machine learning’, *Nature*, 549(7671), pp. 195–202. Available at: <https://doi.org/10.1038/nature23474>.
- Bojarski, M. *et al.* (2016) ‘End to End Learning for Self-Driving Cars’, *arXiv preprint arXiv:1604.07316* [Preprint]. Available at: <http://arxiv.org/abs/1604.07316>.
- Cerezo, M. *et al.* (2021) ‘Variational quantum algorithms’, *Nature Reviews Physics*, 3(9), pp. 625–644. Available at: <https://doi.org/10.1038/s42254-021-00348-9>.
- Cong, I., Choi, S. and Lukin, M.D. (2019) ‘Quantum Convolutional Neural Networks’, *Nature Physics* [Preprint]. Available at: <https://doi.org/10.1038/s41567-019-0648-8>.
- Esteva, A. *et al.* (2017) ‘Dermatologist-level classification of skin cancer with deep neural networks’, *Nature*, 542(7639), pp. 115–118. Available at: <https://doi.org/10.1038/nature21056>.
- Farhi, E. and Neven, H. (2018) ‘Classification with Quantum Neural Networks on Near Term Processors’. Available at: <http://arxiv.org/abs/1802.06002>.
- Fawcett, T. (2006) ‘An introduction to ROC analysis’, *Pattern Recognition Letters*, 27(8), pp. 861–874. Available at: <https://doi.org/10.1016/J.PATREC.2005.10.010>.
- Goodfellow, I., Bengio, Y. and Courville, A. (2016) *Deep Learning*. Cambridge: The MIT Press. Available at: <http://www.deeplearningbook.org> (Accessed: 26 June 2025).
- He, K. *et al.* (2015) ‘Deep Residual Learning for Image Recognition’, in *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE Computer Society, pp. 770–778. Available at: <https://doi.org/10.1109/CVPR.2016.90>.
- Henderson, M. *et al.* (2020) ‘Quantum Convolutional Neural Networks: Powering Image Recognition with Quantum Circuits’, *Quantum*

- Machine Intelligence*, 2(1), p. 2. Available at: <https://doi.org/10.1007/s42484-020-00017-1>.
- Hur, T., Kim, L. and Park, D.K. (2022) 'Quantum convolutional neural network for classical data classification'. Available at: <https://doi.org/10.1007/s42484-021-00061-x>.
- Lecun, Y. *et al.* (1998) 'Gradient-Based Learning Applied to Document Recognition', *Proceedings of the IEEE*, 86(11), pp. 2278–2324. Available at: <https://doi.org/10.1109/5.726791>.
- Mari, A. *et al.* (2020) 'Transfer learning in hybrid classical-quantum neural networks', *Quantum*, 4, p. 340. Available at: <https://doi.org/10.22331/Q-2020-10-09-340>.
- McClean, J.R. *et al.* (2016) 'The theory of variational hybrid quantum-classical algorithms', *New Journal of Physics*, 18(2). Available at: <https://doi.org/10.1088/1367-2630/18/2/023023>.
- Nielsen, M.A. and Chuang, I.L. (2010) *Quantum Computation and Quantum Information*. 10th Edition. Cambridge: Cambridge University Press.
- Parkhi, O.M., Vedaldi, A. and Zisserman, A. (2015) 'Deep Face Recognition', in *Proceedings of the British Machine Vision Conference (BMVC)*, pp. 41.1-41.12. Available at: <https://doi.org/10.5244/C.29.41>.
- Pérez-Salinas, A. *et al.* (2020) 'Data re-uploading for a universal quantum classifier', *Quantum*, 4, p. 226. Available at: <https://doi.org/10.22331/q-2020-02-06-226>.
- Preskill, J. (2018) 'Quantum Computing in the NISQ era and beyond', *Quantum*, 2, p. 79. Available at: <https://doi.org/10.22331/q-2018-08-06-79>.
- Russakovsky, O. *et al.* (2015) 'ImageNet Large Scale Visual Recognition Challenge', *International Journal of Computer Vision*, 115(3), pp. 211–252. Available at: <https://doi.org/10.1007/s11263-015-0816-y>.

- Schuld, M. and Petruccione, F. (2021) *Machine Learning with Quantum Computers*. 2nd edn. Cham: Springer. Available at: <http://www.springer.com/series/10039>.
- Sim, S., Johnson, P.D. and Aspuru-Guzik, A. (2019) ‘Expressibility and entangling capability of parameterized quantum circuits for hybrid quantum-classical algorithms’, *npj Quantum Information*, 5(1), p. 99. Available at: <https://doi.org/10.1002/qute.201900070>.
- Simonyan, K. and Zisserman, A. (2015) ‘Very Deep Convolutional Networks for Large-Scale Image Recognition’, *Proceedings of the 3rd International Conference on Learning Representations (ICLR)* [Preprint]. Available at: <http://arxiv.org/abs/1409.1556>.
- Stehman, S. V. (1997) ‘Selecting and interpreting measures of thematic classification accuracy’, *Remote Sensing of Environment*, 62(1), pp. 77–89. Available at: [https://doi.org/10.1016/S0034-4257\(97\)00083-7](https://doi.org/10.1016/S0034-4257(97)00083-7).
- Sun, C. *et al.* (2017) ‘Revisiting Unreasonable Effectiveness of Data in Deep Learning Era’, in *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. Institute of Electrical and Electronics Engineers Inc., pp. 843–852. Available at: <https://doi.org/10.1109/ICCV.2017.97>.
- Wittek, P. (2014) *Quantum Machine Learning: What Quantum Computing Means to Data Mining*. London: Academic Press.
- Xu, C. *et al.* (2023) ‘Asynchronous federated learning on heterogeneous devices: A survey’, *Computer Science Review*, 50, p. 100595. Available at: <https://doi.org/10.1016/J.COSREV.2023.100595>.