



# Analisis Ketahanan Variational QNN Terhadap Bit Flip dan Depolarizing Noise Pada Subset Dataset MNIST

Gionathan Advent Kristianto Sinaga\*, Sunneng Sandino Berutu, Aninda Astuti

Fakultas Sains Dan Komputer, Prodi Informatika, Universitas Kristen Immanuel, Yogyakarta

Jl. Ukrim No.23, Cupuwatu I, Purwomartani, Kec. Kalasan, Kabupaten Sleman, Daerah Istimewa Yogyakarta, Indonesia

Email: <sup>1,\*</sup>gionatan34768@email.com, <sup>2</sup>Sandinoberutu@email.com, <sup>3</sup>anindaastuti@email.com

Email Penulis Korespondensi: gionatan34768@gmail.com

Submitted: 15/01/2026; Accepted: 25/01/2026; Published: 31/01/2026

**Abstrak**—Perkembangan komputasi kuantum mendorong penggunaan Variational Quantum Neural Network (VQNN) sebagai pendekatan alternatif dalam tugas klasifikasi data. Namun, implementasi VQNN pada era Noisy Intermediate-Scale Quantum (NISQ) masih menghadapi tantangan utama berupa derau kuantum yang dapat menurunkan performa model secara signifikan. Penelitian ini bertujuan untuk menganalisis ketahanan VQNN terhadap pengaruh derau kuantum pada tugas klasifikasi biner menggunakan subset dataset MNIST. Data citra diproses melalui tahap normalisasi dan reduksi dimensi menggunakan Principal Component Analysis (PCA), kemudian dikodekan ke dalam rangkaian kuantum menggunakan angle encoding. Model VQNN dirancang dengan enam qubit dan satu lapisan variational, serta dievaluasi pada dua kondisi, yaitu simulasi kuantum ideal (before noise, statevector) dan simulasi dengan derau (after noise). Penyisipan derau disimulasikan menggunakan Qiskit Aer dengan dua jenis derau, yaitu bit flip dan depolarizing noise, pada berbagai tingkat probabilitas. Hasil eksperimen menunjukkan bahwa pada kondisi ideal, model VQNN mampu mencapai akurasi pengujian sebesar 85,2%. Namun, peningkatan probabilitas derau menyebabkan degradasi performa secara bertahap hingga mendekati ambang klasifikasi acak pada tingkat derau tinggi. Bit flip noise memberikan dampak penurunan performa yang lebih signifikan dibandingkan depolarizing noise. Temuan ini menegaskan bahwa derau kuantum merupakan faktor kritis yang memengaruhi stabilitas VQNN dan menunjukkan pentingnya pengembangan strategi mitigasi derau pada implementasi VQNN di era NISQ.

**Kata Kunci:** Quantum Neural Network; Variational Quantum Classifier; Noise Robustness; MNIST; NISQ

**Abstract**—The advancement of quantum computing has encouraged the use of Variational Quantum Neural Networks (VQNNs) as an alternative approach for data classification tasks. However, the implementation of VQNNs in the Noisy Intermediate-Scale Quantum (NISQ) era still faces major challenges due to quantum noise, which can significantly degrade model performance. This study aims to analyze the robustness of VQNNs against quantum noise in a binary classification task using a subset of the MNIST dataset. Image data are processed through normalization and dimensionality reduction using Principal Component Analysis (PCA), and subsequently encoded into quantum circuits using the angle encoding method. The VQNN model is designed with six qubits and a single variational layer, and evaluated under two conditions: an ideal quantum simulation (before noise, statevector) and a noisy quantum simulation (after noise). Quantum noise is simulated using Qiskit Aer, considering two types of noise, namely bit flip and depolarizing noise, across various probability levels. Experimental results show that under ideal conditions, the VQNN achieves a test accuracy of 85.2%. However, increasing noise probabilities lead to a gradual degradation in performance, approaching the random classification threshold at high noise levels. Bit flip noise causes a more severe performance decline compared to depolarizing noise. These findings confirm that quantum noise is a critical factor affecting the stability of VQNNs and highlight the importance of developing effective noise mitigation strategies for VQNN implementations in the NISQ era.

**Kata Kunci:** Quantum Neural Network; Variational Quantum Classifier; Noise Robustness; MNIST; NISQ

## 1. PENDAHULUAN

Perkembangan komputasi kuantum mendorong munculnya pendekatan baru dalam menangani permasalahan pembelajaran mesin yang memiliki korelasi kompleks dan sulit diselesaikan dengan metode klasik. Dalam konteks ini, quantum machine learning berkembang sebagai bidang interdisipliner yang berupaya melampaui keterbatasan classical machine learning dan neural networks. Model pembelajaran berbasis komputer kuantum berpotensi memiliki kemampuan representasi yang lebih kuat, komputasi yang lebih cepat, serta generalisasi yang lebih baik dengan jumlah data yang lebih sedikit. Penelitian tersebut memperkenalkan Variational Quantum Neural Networks (VQNN), yaitu arsitektur hibrida kuantum-klasik yang mengintegrasikan rangkaian kuantum terparameterisasi sebagai bagian dari jaringan saraf untuk tugas klasifikasi citra. VQNN menunjukkan konvergensi komputasi yang lebih cepat dibandingkan QNN konvensional, dengan tingkat akurasi pelatihan yang tetap memadai pada dataset dengan kompleksitas berbeda [1].

Quantum Neural Network (QNN) mengadaptasi prinsip jaringan saraf ke dalam rangkaian kuantum berbasis parameterized quantum circuits dengan memanfaatkan qubit sebagai unit informasi utama. Das dan Bolisetti (2023) mengusulkan arsitektur Variational Quantum Neural Networks (VQNNs), yaitu model hibrida kuantum-klasik yang mengintegrasikan rangkaian kuantum terparameterisasi sebagai lapisan input jaringan saraf. Dalam pendekatan ini, fungsi biaya QNN diencode ke dalam fase relatif keadaan superposisi di ruang Hilbert, sementara parameter jaringan dioptimalkan menggunakan algoritma optimisasi kuantum seperti Quantum Approximate Optimization Algorithm (QAOA). Pendekatan ini menunjukkan bahwa QNN dapat mencapai performa klasifikasi yang kompetitif dengan kompleksitas parameter yang lebih efisien dibandingkan pendekatan klasik [1]. Selain itu, berbagai arsitektur QNN, seperti Hybrid QNN, Deep QNN, Quantum Convolutional Neural



Network, dan EfficientSU2 ansatz, telah terbukti efektif dalam meningkatkan akurasi pada kondisi ideal berbasis simulasi.

Meskipun QNN menunjukkan potensi yang menjanjikan dalam berbagai skenario ideal, implementasinya pada perangkat kuantum nyata masih menghadapi tantangan signifikan akibat keterbatasan perangkat Noisy Intermediate-Scale Quantum (NISQ). [2] menegaskan bahwa eksekusi QNN pada perangkat NISQ sangat dipengaruhi oleh derau kuantum, seperti kesalahan gerbang dan ketidakstabilan qubit, yang dapat menurunkan akurasi dan stabilitas inferensi. Sejalan dengan hal tersebut, [3] menunjukkan bahwa keterbatasan jumlah qubit, tingkat noise yang tinggi, serta keterbatasan ketersediaan perangkat kuantum menjadi hambatan utama dalam pelatihan QNN konvensional. Kondisi ini mendorong pengembangan pendekatan noise-aware dan metode hibrida yang lebih adaptif terhadap karakteristik perangkat kuantum saat ini.

Beberapa jenis derau kuantum yang umum dibahas dalam literatur adalah bit flip noise dan depolarizing noise. Bit flip noise menyebabkan pembalikan keadaan qubit dari  $|0\rangle$  ke  $|1\rangle$  atau sebaliknya, sedangkan depolarizing noise menyebabkan keadaan qubit kehilangan informasi dan terdorong menuju distribusi probabilitas merata, sehingga setiap kemungkinan hasil pengukuran memiliki peluang yang hampir sama. Studi sebelumnya menunjukkan bahwa kedua jenis derau ini dapat secara signifikan mempercepat degradasi performa QNN, terutama pada rangkaian variational dengan kedalaman atau jumlah parameter yang berlebihan [4]. Temuan terbaru juga menunjukkan bahwa pada tingkat depolarizing noise yang konstan, rangkaian kuantum variational dengan kedalaman terbatas dapat kehilangan keunggulan asimtotiknya dan menjadi mudah disimulasikan secara klasik, sehingga performa model kuantum mendekati perilaku acak [6].

Berbagai upaya telah dilakukan untuk meningkatkan ketahanan QNN terhadap derau kuantum. Alam dan Ghosh (2022) mengusulkan QNet, yaitu arsitektur modular yang membagi QNN menjadi beberapa sub jaringan kecil untuk mengurangi akumulasi kesalahan. Penelitian lain menunjukkan bahwa teknik error mitigation, seperti measurement error mitigation, dynamic decoupling, dan zero-noise extrapolation, mampu meningkatkan hasil komputasi kuantum agar lebih mendekati kondisi ideal, meskipun efektivitasnya sangat bergantung pada jenis rangkaian dan perangkat keras yang digunakan [7][8]. Selain itu, pendekatan hybrid quantum-classical juga banyak diusulkan sebagai solusi pragmatis untuk meningkatkan stabilitas dan performa QNN di lingkungan yang mengandung derau [9][10][11].

Dalam konteks klasifikasi citra, dataset MNIST masih menjadi tolak ukur utama untuk mengevaluasi performa QNN dan model hybrid. Sejumlah studi menunjukkan bahwa QNN dan hybrid QNN mampu mencapai akurasi tinggi pada MNIST dalam kondisi ideal, namun performanya menurun secara konsisten ketika noise diperkenalkan ke dalam rangkaian kuantum [8]. Penelitian Long et al. (2025) juga menunjukkan bahwa rangkaian dengan kedalaman moderat memberikan keseimbangan terbaik antara ekspresivitas dan stabilitas, sementara rangkaian yang terlalu dalam cenderung mengalami instabilitas pelatihan dan barren plateaus.

Meskipun berbagai penelitian tersebut telah membahas dampak derau kuantum terhadap QNN, sebagian besar studi berfokus pada pengembangan arsitektur tertentu, peningkatan optimisasi, atau penerapan teknik mitigasi derau. Analisis eksperimental yang secara sistematis membandingkan performa QNN pada kondisi ideal (before noise) dan kondisi terderau (after noise) dengan variasi tingkat derau yang terkontrol masih relatif terbatas, khususnya pada model QNN sederhana yang mencerminkan keterbatasan realistik era NISQ.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menganalisis ketahanan QNN terhadap derau kuantum dengan menggunakan subset dataset MNIST sebagai studi kasus klasifikasi biner. Data MNIST diproses melalui normalisasi dan reduksi dimensi menggunakan PCA agar sesuai dengan jumlah qubit yang digunakan. Model QNN dirancang dengan jumlah qubit terbatas dan satu lapisan variational untuk merepresentasikan kondisi realistik perangkat NISQ, sementara derau kuantum disimulasikan langsung pada level rangkaian menggunakan bit flip noise dan depolarizing noise dengan berbagai tingkat probabilitas.

Pendekatan yang digunakan dalam penelitian ini adalah evaluasi komparatif dengan menjadikan kondisi before noise sebagai baseline dan menganalisis degradasi performa pada kondisi after noise. Pendekatan ini memungkinkan pengamatan yang lebih terukur mengenai pola penurunan akurasi serta perbedaan karakteristik dampak antara jenis derau yang digunakan. Dengan demikian, penelitian ini tidak hanya menilai performa QNN dalam kondisi ideal, tetapi juga mengevaluasi keandalannya pada kondisi yang lebih mendekati perangkat kuantum nyata.

Kontribusi utama dari penelitian ini adalah penyajian analisis eksperimental yang sistematis dan mudah direplikasi mengenai ketahanan QNN terhadap derau kuantum pada tugas klasifikasi citra MNIST. Hasil penelitian ini diharapkan dapat memperkaya pemahaman mengenai batas performa QNN di era NISQ, sekaligus menjadi referensi dalam pengembangan arsitektur QNN yang lebih robust dan strategi mitigasi derau pada penelitian komputasi kuantum selanjutnya.

## 2. METODOLOGI PENELITIAN

Penelitian ini merupakan penelitian eksperimental kuantitatif yang bertujuan untuk mengevaluasi ketahanan Quantum Neural Network terhadap pengaruh derau kuantum pada tugas klasifikasi citra. Fokus penelitian diarahkan pada analisis perubahan performa QNN ketika dijalankan pada lingkungan Noisy Intermediate-Scale

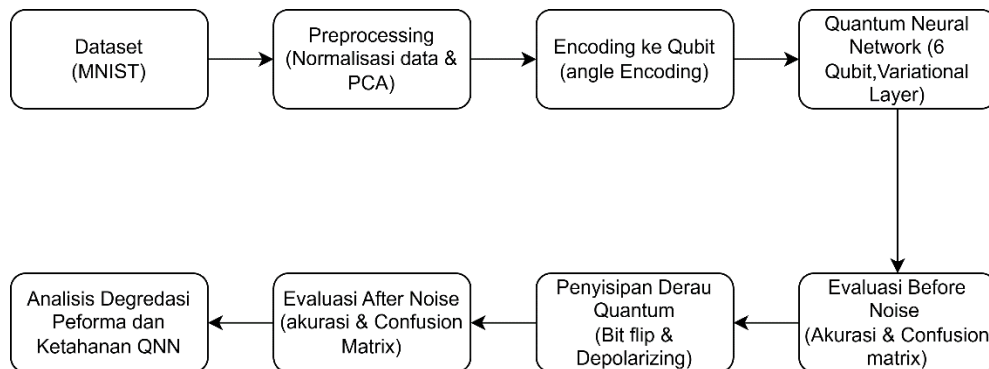
Quantum (NISQ), di mana keberadaan noise menjadi faktor utama yang memengaruhi keandalan inferensi. [2] menekankan bahwa derau kuantum pada perangkat NISQ dapat secara signifikan menurunkan performa QNN, sehingga diperlukan pendekatan evaluasi dan optimisasi yang bersifat noise-aware. Sejalan dengan hal tersebut, [3] menunjukkan bahwa pengujian QNN pada sistem kuantum nyata dengan mempertimbangkan keterbatasan perangkat dan noise merupakan langkah penting untuk menilai kelayakan dan stabilitas model kuantum dalam aplikasi klasifikasi citra.

## 2.1 Tahapan Penelitian

Tahapan penelitian dirancang secara sistematis untuk menggambarkan alur eksperimen dari pengolahan data hingga analisis ketahanan QNN terhadap derau kuantum. Secara umum, tahapan penelitian terdiri dari pengolahan data, perancangan model QNN, penyisipan derau, serta evaluasi performa model seperti yang diilustrasikan dalam Gambar 1.

Dataset yang digunakan merupakan subset dari dataset MNIST yang telah disesuaikan untuk tugas klasifikasi biner. Data citra terlebih dahulu melalui tahap preprocessing yang mencakup normalisasi dan reduksi dimensi menggunakan PCA. Normalisasi dilakukan untuk menyesuaikan skala nilai piksel agar sesuai dengan kebutuhan komputasi kuantum, sedangkan PCA digunakan untuk menyesuaikan jumlah fitur dengan jumlah qubit yang tersedia. Dataset ini dipilih karena telah banyak digunakan sebagai tolak ukur dalam penelitian Quantum Machine Learning, sehingga memungkinkan perbandingan hasil secara konseptual dengan studi terdahulu.

Setelah preprocessing, data dikodekan ke dalam rangkaian kuantum menggunakan metode angle encoding. Metode angle encoding dipilih karena efisien dalam merepresentasikan data kontinu serta menghasilkan rangkaian kuantum dengan kedalaman relatif rendah, sehingga lebih sesuai untuk lingkungan NISQ yang rentan terhadap akumulasi derau. Model QNN kemudian dirancang menggunakan enam qubit dengan satu lapisan variational yang terdiri dari gerbang rotasi dan pola entanglement linear. Model dievaluasi pada dua kondisi, yaitu simulasi kuantum ideal (before noise, statevector) dan simulasi dengan derau (after noise), dengan derau disimulasikan menggunakan bit flip noise dan depolarizing noise pada beberapa tingkat probabilitas.



**Gambar 1.** Arsitektur Penelitian

### 2.2.1 Dataset Mnist

Dataset yang digunakan dalam penelitian ini adalah subset dari dataset MNIST yang berisi citra digit tulisan tangan. Penggunaan subset dataset dilakukan untuk menyesuaikan kompleksitas data dengan keterbatasan jumlah qubit, kapasitas representasi, serta kedalaman rangkaian kuantum pada model QNN, sebagaimana direkomendasikan dalam berbagai penelitian QML pada era NISQ. Pendekatan ini memungkinkan proses pembelajaran kuantum tetap stabil sekaligus menghindari peningkatan akumulasi derau yang berlebihan akibat rangkaian kuantum yang terlalu dalam. Subset data dipilih secara selektif agar tetap merepresentasikan karakteristik utama dataset MNIST, khususnya pola visual digit dan variasi bentuk tulisan tangan, namun tetap dapat diproses secara efisien oleh arsitektur QNN dengan sumber daya kuantum terbatas. Strategi pemilihan subset seperti ini telah banyak digunakan dalam studi evaluasi QNN dan variational quantum classifiers untuk menjaga keseimbangan antara kompleksitas data dan keterbatasan perangkat NISQ. Dataset selanjutnya dibagi menjadi data pelatihan sebanyak 1600 sampel dan data pengujian sebanyak 400 sampel, dengan data uji yang terdiri dari dua kelas, masing-masing sebanyak 200 data per kelas. Pembagian ini dilakukan untuk memastikan distribusi kelas yang seimbang sehingga tidak menimbulkan bias evaluasi dan memungkinkan analisis performa model yang lebih objektif, sebagaimana diterapkan dalam penelitian-penelitian QNN berbasis MNIST sebelumnya.

### 2.2.2 Preprocessing

Metode reduksi dimensi yang bertujuan untuk memproyeksikan data berdimensi tinggi ke dalam ruang berdimensi lebih rendah dengan tetap mempertahankan sebanyak mungkin informasi penting dari data asli. Proyeksi ini dilakukan dengan mentransformasikan data ke arah komponen utama yang diperoleh dari vektor eigen dengan nilai eigen terbesar. Secara matematis, transformasi data pada PCA dapat dinyatakan sebagai berikut:

$$Z = XW \tag{1}$$


Di mana :X merupakan matriks data asli,W adalah matriks vektor eigen utama,Z adalah representasi data pada ruang dimensi yang lebih rendah. Proses awal yang dilakukan adalah normalisasi data, yaitu mengubah nilai piksel citra ke dalam rentang tertentu agar memiliki skala yang seragam. Normalisasi diperlukan untuk menjaga stabilitas proses data encoding ke dalam parameter gerbang kuantum, serta untuk mencegah dominasi fitur tertentu yang dapat menyebabkan ketidakseimbangan amplitudo dan fase pada keadaan kuantum [12]. Selanjutnya, dilakukan reduksi dimensi menggunakan PCA. PCA digunakan untuk menurunkan jumlah fitur input dengan tetap mempertahankan informasi utama yang paling representatif dari data citra. Reduksi dimensi ini penting untuk menyesuaikan jumlah fitur dengan jumlah qubit yang tersedia, sekaligus mengurangi kompleksitas rangkaian kuantum dan potensi akumulasi derau pada model QNN. Pendekatan PCA telah banyak diterapkan dalam penelitian klasifikasi MNIST berbasis QNN dan variational quantum classifiers sebagai strategi untuk menjaga keseimbangan antara kapasitas representasi model dan keterbatasan sumber daya kuantum pada era NISQ[9][8][10].

### 2.2.3 Encoding Ke Qubit

Data hasil preprocessing selanjutnya dikodekan ke dalam rangkaian kuantum menggunakan metode angle encoding, yaitu dengan memetakan setiap nilai fitur hasil reduksi dimensi ke dalam sudut rotasi pada gerbang kuantum satu-qubit. Pendekatan ini banyak digunakan dalam QNN dan variational quantum classifiers karena mampu merepresentasikan data kontinu secara langsung ke dalam parameter rangkaian kuantum tanpa memerlukan jumlah qubit yang besar[13][14]. Pemilihan angle encoding didasarkan pada efisiensi kedalaman rangkaian yang dihasilkan. Dengan memanfaatkan rotasi parametrik, metode ini memungkinkan pemetaan informasi klasik ke dalam keadaan kuantum dengan struktur rangkaian yang relatif sederhana. Hal ini penting dalam konteks perangkat NISQ, karena kedalaman rangkaian yang rendah dapat mengurangi akumulasi derau kuantum selama proses eksekusi dan meningkatkan stabilitas pembelajaran QNN [4]. Selain itu, angle encoding telah terbukti efektif dalam tugas klasifikasi citra berbasis MNIST pada berbagai penelitian QNN dan model hybrid quantum–classical, khususnya ketika dikombinasikan dengan teknik reduksi dimensi seperti PCA. Pendekatan ini menjaga keseimbangan antara kapasitas representasi data dan keterbatasan sumber daya kuantum, sehingga sesuai dengan tujuan penelitian ini yang berfokus pada analisis ketahanan QNN terhadap derau kuantum [8].

### 2.2.4 Quantum Neural Network

Arsitektur QNN dirancang dengan mempertimbangkan keterbatasan jumlah qubit dan kedalaman rangkaian pada era NISQ, sehingga digunakan rangkaian kuantum parametrik yang relatif sederhana namun tetap representatif. Secara umum, arsitektur QNN yang digunakan terdiri dari tahap pemetaan fitur (feature map) untuk mengkode data klasik ke dalam keadaan kuantum, diikuti oleh lapisan variational (ansatz) yang berfungsi sebagai komponen pembelajaran utama. Struktur arsitektur QNN yang digunakan dalam penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur Quantum Neural Network

Data yang telah melalui tahap encoding selanjutnya diproses menggunakan QNN yang dirancang dengan enam qubit dan satu lapisan variational. Pemilihan jumlah qubit ini disesuaikan dengan jumlah fitur hasil reduksi dimensi menggunakan PCA, sehingga setiap qubit merepresentasikan satu fitur utama dari data citra. Pendekatan ini bertujuan untuk menjaga keseimbangan antara kapasitas representasi model dan keterbatasan sumber daya komputasi kuantum pada era NISQ. Arsitektur QNN dengan jumlah qubit terbatas dan kedalaman rangkaian yang rendah direkomendasikan dalam berbagai penelitian karena cenderung lebih stabil dan kurang sensitif terhadap akumulasi derau kuantum dibandingkan rangkaian yang lebih dalam. Arsitektur QNN yang digunakan dalam penelitian ini terdiri dari tiga komponen utama, yaitu lapisan encoding, lapisan variational, dan lapisan pengukuran (measurement). Lapisan encoding berfungsi untuk memetakan informasi klasik dari data citra hasil PCA ke dalam keadaan kuantum menggunakan metode angle encoding, sebagaimana telah dijelaskan pada tahap sebelumnya. Keadaan kuantum awal yang terbentuk kemudian diproses lebih lanjut oleh lapisan variational untuk mengekstraksi pola dan hubungan antar fitur dalam ruang kuantum. Lapisan variational merupakan inti dari proses pembelajaran pada QNN. Pada lapisan ini digunakan kombinasi gerbang rotasi parametrik, seperti rotasi pada sumbu X, Y, atau Z, yang masing-masing memiliki parameter sudut rotasi yang dapat dilatih. Parameter-parameter ini berperan serupa dengan bobot (weights) pada jaringan saraf klasik. Selain itu, lapisan variational juga dilengkapi dengan pola entanglement linear yang mana diimplementasikan menggunakan gerbang CNOT yang menghubungkan antar qubit untuk membentuk korelasi kuantum antar fitur. Keberadaan entanglement ini penting


karena memungkinkan QNN memodelkan hubungan non-linear yang kompleks, yang sulit direpresentasikan oleh model klasik konvensional. Selama proses pelatihan, parameter-parameter pada lapisan variational dioptimasi menggunakan pendekatan hybrid quantum–classical. Dalam pendekatan ini, rangkaian kuantum digunakan untuk menghasilkan output probabilistik melalui proses pengukuran, sedangkan proses optimisasi parameter dilakukan pada komputer klasik menggunakan algoritma optimisasi berbasis gradien. Pendekatan hybrid ini merupakan praktik standar dalam pelatihan QNN pada era NISQ, mengingat keterbatasan perangkat kuantum saat ini yang belum memungkinkan proses optimisasi dilakukan sepenuhnya secara kuantum. Output dari QNN diperoleh melalui proses pengukuran keadaan qubit pada basis komputasi. Hasil pengukuran ini kemudian diolah menjadi nilai probabilitas untuk masing-masing kelas. Karena penelitian ini berfokus pada klasifikasi biner, keputusan akhir klasifikasi ditentukan berdasarkan nilai probabilitas tertinggi atau ambang batas tertentu. Dengan demikian, QNN menghasilkan prediksi kelas untuk setiap data uji berdasarkan distribusi probabilitas hasil pengukuran kuantum. Penggunaan satu lapisan variational dalam penelitian ini dipilih secara sengaja untuk menjaga kompleksitas rangkaian tetap rendah dan meminimalkan akumulasi derau kuantum selama eksekusi rangkaian. Penelitian sebelumnya menunjukkan bahwa peningkatan kedalaman rangkaian dapat memperburuk performa QNN akibat akumulasi kesalahan kuantum serta munculnya permasalahan barren plateau pada proses pelatihan. Oleh karena itu, arsitektur QNN yang sederhana ini dipandang lebih sesuai untuk tujuan analisis ketahanan QNN terhadap derau kuantum. Dengan demikian, rancangan QNN yang terdiri dari enam qubit dan satu lapisan variational ini menjadi fondasi utama dalam penelitian untuk mengevaluasi ketahanan QNN terhadap berbagai jenis derau kuantum. Arsitektur ini memungkinkan analisis yang adil dan terkontrol terhadap pengaruh bit flip noise dan depolarizing noise, sekaligus memberikan gambaran yang jelas mengenai kemampuan dan keterbatasan QNN pada kondisi ideal (before noise) maupun kondisi terderau (after noise).

### 2.2.5 Evaluasi Akurasi Before Noise

Setelah proses pelatihan selesai, model QNN terlebih dahulu dievaluasi pada kondisi ideal tanpa derau kuantum. Evaluasi ini dilakukan untuk mengukur kemampuan dasar model dalam melakukan klasifikasi citra ketika seluruh operasi kuantum berjalan secara sempurna, tanpa adanya gangguan yang menyerupai kondisi perangkat kuantum nyata. Tahap ini sangat penting karena berfungsi sebagai baseline performa yang merepresentasikan kemampuan maksimum QNN dalam kondisi ideal. Evaluasi performed menggunakan dua metrik utama, yaitu akurasi dan confusion matrix. Akurasi digunakan untuk memberikan gambaran kuantitatif mengenai tingkat keberhasilan model dalam mengklasifikasikan data uji secara keseluruhan. Sementara itu, confusion matrix digunakan untuk menganalisis distribusi prediksi model pada masing-masing kelas, sehingga dapat diketahui secara lebih rinci jumlah prediksi yang benar maupun kesalahan klasifikasi yang terjadi pada setiap kelas. Penggunaan confusion matrix pada tahap ini memungkinkan analisis keseimbangan performa antar kelas serta memastikan bahwa nilai akurasi yang tinggi tidak dihasilkan oleh bias terhadap salah satu kelas tertentu. Hasil evaluasi pada kondisi before noise ini kemudian digunakan sebagai titik acuan utama untuk membandingkan performa model setelah derau kuantum disisipkan. Dengan demikian, setiap perubahan atau penurunan performa yang terjadi pada tahap selanjutnya dapat diinterpretasikan secara objektif sebagai dampak langsung dari derau kuantum, bukan akibat kelemahan arsitektur model atau kualitas data.

### 2.2.6 Penyisipan Derau Kuantum

Setelah memperoleh hasil evaluasi pada kondisi ideal, tahap selanjutnya adalah melakukan penyisipan derau kuantum (quantum noise injection) ke dalam rangkaian QNN. Tahap ini bertujuan untuk mensimulasikan kondisi perangkat kuantum nyata yang bersifat tidak ideal, khususnya pada era NISQ, di mana operasi gerbang kuantum rentan terhadap kesalahan dan gangguan lingkungan. Dalam penelitian ini, dua jenis derau kuantum yang umum dijumpai pada sistem kuantum digunakan, yaitu bit flip noise dan depolarizing noise. Bit flip noise merepresentasikan kesalahan yang menyebabkan keadaan qubit berubah secara langsung dari  $|0\rangle$  menjadi  $|1\rangle$  atau sebaliknya. Sementara itu, depolarizing noise merepresentasikan gangguan yang lebih umum, di mana keadaan qubit dicampurkan dengan keadaan acak secara probabilistik, sehingga informasi kuantum mengalami degradasi secara bertahap. Penyisipan derau dilakukan dengan menggunakan beberapa tingkat probabilitas noise, yaitu [0.00, 0.05, 0.10, 0.15, 0.20, 0.25, 0.30, 0.35, dan 0.40]. Pendekatan penyisipan derau secara eksplisit pada rangkaian QNN juga sejalan dengan penelitian yang menunjukkan bahwa QNN tidak hanya terdampak oleh noise, tetapi juga mampu merefleksikan karakteristik kanal noise melalui perubahan fungsi biaya dan performa klasifikasi [15]. Derau kuantum disisipkan setelah setiap operasi gerbang kuantum (gate-based noise) untuk mensimulasikan kondisi realistis perangkat kuantum NISQ seperti yang digambarkan pada Gambar 3 berikut.



**Gambar 3.** Diagram rangkaian VQC dengan penyisipan kanal noise (E)



Penyisipan derau kuantum dilakukan menggunakan pendekatan gate-based noise, di mana kanal noise diterapkan setelah setiap gerbang kuantum utama dalam rangkaian. Seperti ditunjukkan pada Gambar 3, kanal noise (E) disisipkan setelah gerbang rotasi parametrik dan gerbang entanglement (CNOT). Pendekatan ini digunakan untuk mensimulasikan kondisi perangkat kuantum pada era Noisy Intermediate-Scale Quantum (NISQ), di mana setiap operasi gerbang rentan terhadap kesalahan akibat gangguan lingkungan dan keterbatasan perangkat keras. Kanal noise (E) merepresentasikan model bit flip noise dan depolarizing noise yang diimplementasikan menggunakan simulator Qiskit Aer. Bit flip noise memodelkan kesalahan pembalikan keadaan qubit, sedangkan depolarizing noise memodelkan pencampuran keadaan kuantum dengan keadaan acak secara probabilistik.

Nilai probabilitas ini merepresentasikan peluang terjadinya kesalahan pada setiap operasi kuantum yang terdampak derau. Probabilitas 0.00 menunjukkan kondisi ideal tanpa derau, sedangkan probabilitas yang lebih tinggi mencerminkan kondisi perangkat kuantum yang semakin tidak stabil. Setiap tingkat noise diuji secara terpisah dengan menggunakan data uji yang sama, sehingga perbandingan performa antar tingkat noise dan antar jenis derau dapat dilakukan secara adil dan konsisten. Pendekatan ini memungkinkan analisis yang sistematis terhadap pola degradasi performa QNN seiring dengan meningkatnya tingkat derau, serta memungkinkan identifikasi jenis derau yang memberikan dampak paling signifikan terhadap hasil klasifikasi. Dengan menyisipkan bit flip noise dan depolarizing noise pada berbagai tingkat probabilitas, penelitian ini bertujuan untuk mengevaluasi ketahanan QNN terhadap gangguan kuantum. Hasil dari tahap ini menjadi dasar utama dalam menganalisis stabilitas model QNN dan keterbatasannya ketika diterapkan pada perangkat kuantum realistik yang masih memiliki tingkat derau tinggi.

### 2.2.7 Evaluasi Akurasi After Noise

Setelah rangkaian QNN terpapar derau kuantum, model dievaluasi kembali pada kondisi after noise menggunakan data uji yang sama seperti pada evaluasi kondisi before noise. Pendekatan ini dilakukan untuk menjaga validitas eksperimen, sehingga setiap perubahan performa yang terjadi dapat dikaitkan secara langsung dengan pengaruh derau kuantum, bukan akibat perbedaan distribusi data atau variasi sampel uji. Evaluasi performa model dilakukan menggunakan metrik akurasi dan confusion matrix. Akurasi digunakan sebagai indikator utama untuk mengukur kemampuan klasifikasi model secara keseluruhan setelah terpapar derau. Metrik ini umum digunakan dalam penelitian QML karena mampu memberikan gambaran kuantitatif yang jelas mengenai degradasi performa akibat gangguan pada operasi kuantum. Sementara itu, confusion matrix digunakan untuk menganalisis distribusi prediksi benar dan salah pada masing-masing kelas secara lebih rinci. Penggunaan confusion matrix pada kondisi after noise menjadi penting karena derau kuantum tidak selalu memengaruhi setiap kelas secara simetris. Beberapa jenis derau dapat menyebabkan kecenderungan kesalahan klasifikasi pada kelas tertentu, sehingga analisis berbasis akurasi saja tidak cukup untuk memahami perilaku model secara menyeluruh. Dengan menganalisis nilai diagonal utama dan elemen di luar diagonal pada confusion matrix, dapat diketahui sejauh mana derau mengganggu kemampuan QNN dalam mempertahankan konsistensi keputusan klasifikasi. Evaluasi dilakukan pada beberapa tingkat probabilitas derau yang telah ditentukan, baik untuk bit flip noise maupun depolarizing noise. Dengan demikian, hasil evaluasi after noise tidak hanya menunjukkan penurunan performa secara statis, tetapi juga menggambarkan perubahan perilaku model QNN secara bertahap seiring dengan meningkatnya tingkat derau kuantum.

### 2.2.8 Analisis Degradasi Performa dan Ketahanan QNN

Tahap akhir penelitian adalah melakukan analisis degradasi performa dengan membandingkan hasil evaluasi sebelum dan sesudah derau ditambahkan. Analisis ini bertujuan untuk menilai tingkat ketahanan QNN terhadap derau kuantum, serta mengidentifikasi jenis derau yang memberikan dampak paling signifikan terhadap penurunan performa. Hasil analisis ini menjadi dasar untuk menarik kesimpulan mengenai stabilitas dan keandalan QNN pada era perangkat kuantum saat ini.

## 2.3 Alur Eksperimen dan Evaluasi Model

Berdasarkan Gambar 1, proses dimulai dari penggunaan subset dataset MNIST yang kemudian diproses melalui tahap preprocessing. Pada tahap ini, normalisasi data dilakukan menggunakan persamaan berikut:

$$x' = \frac{x}{x_{\max}} \quad (2)$$

Di mana  $x$  merupakan nilai piksel asli,  $x_{\max}$  adalah nilai maksimum piksel pada citra, dan  $x'$  adalah nilai hasil normalisasi. Persamaan normalisasi ini merupakan pendekatan yang umum digunakan dalam penelitian QNN dan VQC berbasis citra MNIST untuk menjaga stabilitas proses angle encoding serta mencegah dominasi fitur tertentu pada parameter rotasi gerbang kuantum [8]. Setelah tahap preprocessing dan encoding selesai, data diproses menggunakan model QNN yang telah dirancang. Evaluasi performa pertama dilakukan pada kondisi ideal tanpa derau kuantum (before noise) untuk memperoleh nilai baseline performa model. Selanjutnya, derau kuantum disisipkan ke dalam rangkaian QNN dalam bentuk bit flip noise dan depolarizing noise, dan model dievaluasi kembali pada kondisi telah di masukkan derau. Pendekatan evaluasi komparatif antara kondisi ideal dan kondisi

terpengaruh derau ini banyak digunakan dalam studi ketahanan QNN untuk mengisolasi dampak langsung derau terhadap performa model.

Performa model diukur menggunakan metrik akurasi, yang dihitung berdasarkan hasil confusion matrix dengan persamaan sebagai berikut:

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \tag{3}$$

Di mana TP (True Positive) dan TN (True Negative) menunjukkan jumlah prediksi yang benar, sedangkan FP (False Positive) dan FN (False Negative) menunjukkan jumlah prediksi yang salah. Penggunaan metrik akurasi dan confusion matrix sebagai indikator utama performa klasifikasi QNN merupakan praktik yang lazim dan direkomendasikan dalam penelitian QNN berbasis MNIST, khususnya untuk menganalisis degradasi performa akibat derau kuantum [8]. Nilai akurasi pada kondisi before noise dan after noise kemudian dibandingkan untuk mengamati pola penurunan performa secara kuantitatif. Analisis ini digunakan untuk menilai sejauh mana ketahanan QNN terhadap derau kuantum, serta untuk membandingkan perbedaan dampak antara bit flip noise dan depolarizing noise terhadap stabilitas dan keandalan model. Pendekatan evaluasi seperti ini selaras dengan metodologi yang digunakan dalam penelitian-penelitian sebelumnya yang berfokus pada karakterisasi noise dan robustnes QNN pada era NISQ.

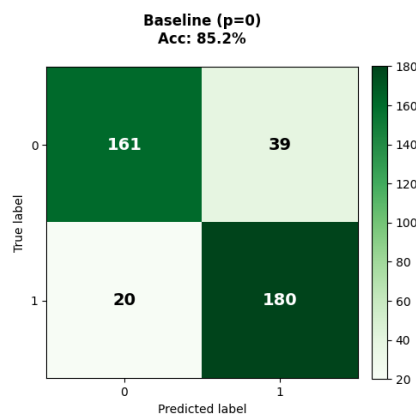
### 3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengujian QNN pada tugas klasifikasi citra menggunakan subset dataset MNIST serta membahas dampak derau kuantum terhadap performa model. Evaluasi dilakukan pada dua kondisi utama, yaitu kondisi ideal tanpa derau dan kondisi dengan derau kuantum. Fokus utama pembahasan diarahkan pada analisis ketahanan QNN terhadap variasi jenis dan tingkat derau, serta implikasinya terhadap stabilitas model pada era NISQ. Hasil penelitian disajikan dalam bentuk nilai akurasi, confusion matrix, serta analisis degradasi performa. Penyajian hasil ini bertujuan untuk memberikan gambaran menyeluruh mengenai perilaku QNN ketika beroperasi pada kondisi ideal dan ketika menghadapi gangguan kuantum yang menyerupai kondisi perangkat kuantum nyata.

#### 3.1 Hasil Evaluasi Model pada Kondisi Before Noise

Evaluasi awal dilakukan pada kondisi tanpa derau kuantum untuk mengetahui performa dasar QNN sebelum diberikan gangguan apa pun. Model diuji menggunakan 400 data uji, yang terdiri dari 200 data kelas 0 dan 200 data kelas 1, sehingga distribusi kelas bersifat seimbang. Kondisi ini memungkinkan evaluasi performa dilakukan secara objektif tanpa bias akibat ketidakseimbangan data. Berdasarkan hasil pengujian, QNN dengan enam qubit dan satu lapisan variational mampu mencapai akurasi pengujian sebesar 85,25% Yang ditunjukkan pada Gambar 3. Nilai ini menunjukkan bahwa pada kondisi ideal, QNN mampu mempelajari pola data citra dari subset MNIST dengan cukup baik. Tingginya akurasi baseline ini mengindikasikan bahwa kombinasi antara tahap preprocessing, metode encoding, dan arsitektur rangkaian kuantum yang digunakan telah mampu merepresentasikan informasi citra secara efektif dalam ruang kuantum.

Selain itu, hasil ini juga menunjukkan bahwa penggunaan Principal Component Analysis (PCA) pada tahap preprocessing tidak mengorbankan kualitas informasi penting dari data citra. Meskipun PCA melakukan reduksi dimensi untuk menyesuaikan jumlah fitur dengan jumlah qubit yang tersedia, akurasi baseline yang tetap tinggi menandakan bahwa komponen utama yang dipertahankan masih cukup representatif untuk mendukung proses klasifikasi. Dengan demikian, PCA terbukti efektif sebagai strategi kompromi antara keterbatasan sumber daya kuantum dan kebutuhan representasi data yang informatif. Evaluasi performa tidak hanya dilakukan melalui akurasi, tetapi juga menggunakan confusion matrix untuk melihat distribusi prediksi model pada masing-masing kelas.



**Gambar 4.** Confusion Matrix QNN pada Kondisi Before Noise

Pada confusion matrix ini, sumbu vertikal (true label) merepresentasikan kelas sebenarnya dari data uji, sedangkan sumbu horizontal (predicted label) menunjukkan kelas yang diprediksi oleh model QNN. Nilai yang terletak pada diagonal utama, yaitu bagian kiri-atas dan kanan-bawah matriks, menunjukkan jumlah prediksi yang benar, sementara nilai di luar diagonal menggambarkan jumlah kesalahan klasifikasi. Secara umum, semakin besar nilai pada diagonal utama dibandingkan nilai di luar diagonal, maka semakin baik performa model dalam melakukan klasifikasi.

Pada kondisi baseline tanpa derau kuantum ( $p = 0$ ) yang terdapat pada Gambar 4, confusion matrix memperlihatkan bahwa QNN mampu bekerja dengan baik dan stabil. Untuk kelas 0, dari seluruh data uji yang termasuk dalam kelas ini, sebanyak 161 data berhasil diklasifikasikan dengan benar sebagai kelas 0, sedangkan 39 data masih salah diprediksi sebagai kelas 1. Sementara itu, pada kelas 1, performa model terlihat lebih baik, di mana 180 data berhasil dikenali dengan benar sebagai kelas 1 dan hanya 20 data yang keliru diklasifikasikan sebagai kelas 0. Jika dilihat secara keseluruhan, jumlah prediksi benar mencapai 341 data, jauh lebih besar dibandingkan jumlah kesalahan klasifikasi yang hanya 59 data. Perbandingan ini menunjukkan bahwa pada kondisi ideal, tanpa adanya gangguan derau, QNN mampu mengenali pola data dengan baik dan menghasilkan keputusan klasifikasi yang konsisten.


Confusion matrix pada kondisi baseline ini berperan sebagai titik acuan utama dalam penelitian. Hasil tersebut merepresentasikan performa maksimum QNN pada kondisi ideal sebelum adanya gangguan derau kuantum. Dengan adanya baseline yang kuat dan seimbang, setiap penurunan performa yang muncul pada kondisi bit flip noise dan depolarizing noise dapat dianalisis secara lebih objektif sebagai dampak langsung dari derau kuantum, bukan disebabkan oleh kelemahan arsitektur model atau kualitas data. Dengan demikian, confusion matrix baseline tidak hanya menunjukkan bahwa QNN bekerja optimal pada kondisi tanpa derau, tetapi juga menjadi dasar penting dalam mengevaluasi ketahanan QNN terhadap berbagai jenis derau kuantum pada tahap analisis selanjutnya.

### 3.2 Hasil Evaluasi Model Pada Kondisi After Noise

Setelah evaluasi pada kondisi ideal, derau kuantum disisipkan ke dalam rangkaian QNN untuk mensimulasikan kondisi perangkat kuantum nyata. Pada penelitian ini digunakan dua jenis derau, yaitu bit flip noise dan depolarizing noise, dengan beberapa tingkat probabilitas. Evaluasi dilakukan menggunakan metrik akurasi dan confusion matrix, karena penelitian ini berfokus pada analisis degradasi performa secara global serta distribusi kesalahan klasifikasi antar kelas pada skenario derau, bukan pada ketidakseimbangan kelas.

#### 3.2.1 Pengaruh Bit Flip Noise terhadap Performa QNN

Hasil pengujian menunjukkan bahwa penambahan bit flip noise menyebabkan penurunan performa QNN yang cukup signifikan. Pada tingkat derau yang rendah, penurunan akurasi masih tergolong moderat, namun seiring dengan meningkatnya probabilitas derau, akurasi model menurun secara tajam. Fenomena ini terjadi karena bit flip noise secara langsung mengubah keadaan qubit dari  $|0\rangle$  menjadi  $|1\rangle$  atau sebaliknya, sehingga informasi yang direpresentasikan dalam qubit mengalami distorsi yang cukup besar. Akibatnya, hasil pengukuran yang diperoleh menjadi kurang stabil dan berdampak pada kesalahan klasifikasi. Confusion matrix pada kondisi ini menunjukkan peningkatan jumlah kesalahan prediksi, khususnya pada kelas yang sebelumnya dapat dikenali dengan baik pada kondisi sebelum derau. Hal ini menandakan bahwa bit flip noise memiliki dampak yang kuat terhadap keputusan model.



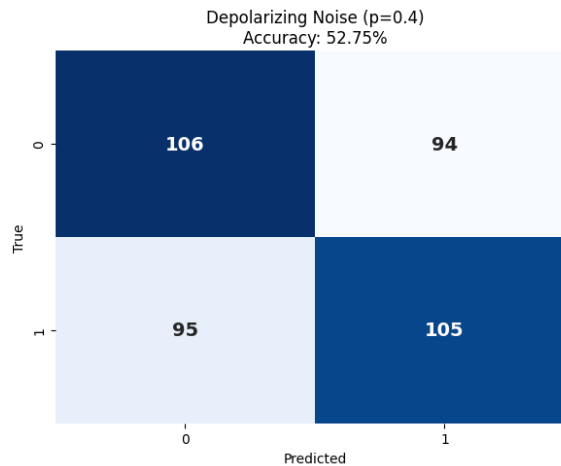
**Gambar 5.** Confusion Matrix QNN dengan Bit Flip Noise

Pada kondisi bit flip noise dengan probabilitas 0,4, confusion matrix menunjukkan terjadinya gangguan yang cukup serius pada kinerja klasifikasi model QNN. Dari 200 data pada kelas 0, hanya 95 data yang berhasil diprediksi dengan benar sebagai kelas 0, sementara 105 data lainnya salah diklasifikasikan sebagai kelas 1. Kondisi serupa juga terjadi pada kelas 1, di mana dari 200 data, hanya 95 data yang dikenali dengan benar sebagai kelas 1,

sedangkan 105 data salah diprediksi sebagai kelas 0. Dengan demikian, jumlah prediksi yang benar dan salah berada pada kondisi hampir seimbang, bahkan kesalahan klasifikasi sedikit lebih dominan dibandingkan prediksi yang benar. Hal ini menunjukkan bahwa model mengalami kesulitan besar dalam membedakan kedua kelas pada tingkat noise yang tinggi. Penyebab utama kondisi ini adalah karakteristik bit flip noise yang bekerja dengan membalik keadaan qubit secara langsung, misalnya dari  $|0\rangle$  menjadi  $|1\rangle$  atau sebaliknya. Pembalikan ini merusak informasi kuantum yang sebelumnya telah dipelajari oleh QNN selama proses pelatihan, sehingga pola yang seharusnya dikenali menjadi tidak konsisten saat inferensi. Ketika semakin banyak qubit mengalami bit flip, keputusan akhir model cenderung mendekati acak. Dampak tersebut tercermin jelas pada confusion matrix, di mana banyak data berpindah ke kelas yang salah. Akibatnya, performa model menurun drastis dengan akurasi hanya mencapai 47,50%, yang mendekati performa tebak acak pada masalah klasifikasi biner. Dalam konteks klasifikasi biner, nilai akurasi di bawah 50% tidak hanya mengindikasikan kegagalan model dalam melakukan klasifikasi, tetapi juga dapat menunjukkan bahwa model mempelajari pola keputusan yang terbalik. Fenomena ini dapat terjadi ketika bit flip noise dengan probabilitas tinggi secara sistematis membalik keadaan qubit yang merepresentasikan fitur data, sehingga hubungan antara fitur input dan label kelas menjadi terdistorsi. Pada kondisi ini, QNN cenderung menghasilkan probabilitas keluaran yang berlawanan dengan pola yang dipelajari pada fase pelatihan, sehingga prediksi yang seharusnya benar justru diklasifikasikan sebagai kelas lawan. Hal ini menjelaskan mengapa jumlah kesalahan klasifikasi sedikit lebih dominan dibandingkan prediksi yang benar pada confusion matrix, serta mengapa performa model berada di bawah ambang klasifikasi acak. Temuan ini menunjukkan bahwa bit flip noise tidak hanya menurunkan akurasi, tetapi juga dapat mengubah perilaku keputusan QNN secara fundamental pada tingkat derau tinggi.

### 3.2.2 Pengaruh Depolarizing Noise terhadap Performa QNN

Berbeda dengan bit flip noise, depolarizing noise menunjukkan pola penurunan performa yang relatif lebih stabil. Meskipun akurasi tetap mengalami penurunan seiring dengan meningkatnya tingkat derau, laju degradasinya cenderung lebih lambat dibandingkan bit flip noise. Hal ini disebabkan oleh karakteristik depolarizing noise yang tidak hanya membalik keadaan qubit, tetapi juga mencampurkan keadaan kuantum dengan probabilitas tertentu. Dampak dari derau ini lebih bersifat menyebar (distributed noise), sehingga gangguan terhadap informasi kuantum tidak selalu bersifat ekstrem pada satu qubit tertentu. Hasil confusion matrix menunjukkan bahwa meskipun terjadi peningkatan kesalahan prediksi, distribusi kesalahan relatif lebih merata. Ini mengindikasikan bahwa QNN masih mampu mempertahankan sebagian kemampuan klasifikasinya pada kondisi depolarizing noise. Fenomena ini konsisten dengan temuan sebelumnya yang menunjukkan bahwa depolarizing noise cenderung mengaburkan informasi kuantum secara bertahap dan dapat mengurangi efektivitas pembelajaran QNN tanpa memberikan peningkatan robustness tambahan pada skenario klasifikasi multi-kelas maupun biner [16].



**Gambar 6.** Confusion Matrix QNN dengan Depolarizing Noise

Pada kondisi depolarizing noise dengan probabilitas yang sama, hasil confusion matrix menunjukkan bahwa dari 200 data kelas 0, sebanyak 106 data berhasil diklasifikasikan dengan benar, sementara 94 data lainnya mengalami kesalahan prediksi. Sementara itu, pada kelas 1, dari total 200 data, sebanyak 105 data diprediksi dengan benar dan 95 data salah diklasifikasikan. Jika dibandingkan dengan bit flip noise, jumlah prediksi yang benar pada depolarizing noise masih lebih besar daripada jumlah kesalahan klasifikasi, meskipun selisihnya relatif tidak terlalu besar. Hal ini mengindikasikan bahwa model QNN masih mampu mempertahankan sebagian kemampuan dalam mengenali dan membedakan pola data pada tingkat noise yang tinggi. Secara karakteristik, depolarizing noise tidak secara langsung membalik keadaan qubit seperti pada bit flip noise, melainkan membuat keadaan qubit menjadi semakin acak secara bertahap dengan mencampurkan keadaan ideal dengan keadaan acak. Akibatnya, informasi kuantum memang mengalami degradasi kualitas, namun efeknya tidak selalu langsung mengubah hasil keputusan klasifikasi. Kondisi ini tercermin pada confusion matrix yang masih didominasi oleh



nilai diagonal utama, yang menandakan jumlah prediksi benar masih relatif tinggi. Oleh karena itu, meskipun terjadi penurunan performa, model QNN pada depolarizing noise masih mampu mencapai akurasi sebesar 52,75%, yang lebih baik dibandingkan dengan skenario bit flip noise pada probabilitas yang sama.

### 3.2.3 Analisis Degradasi Performa QNN

Untuk memperjelas dampak derau terhadap performa model, dilakukan analisis degradasi performa dengan membandingkan akurasi pada kondisi before noise dan after noise. Hasil analisis menunjukkan bahwa peningkatan tingkat derau berbanding lurus dengan penurunan akurasi QNN. Secara umum, bit flip noise menghasilkan degradasi performa yang lebih tajam dibandingkan depolarizing noise. Temuan ini menunjukkan bahwa jenis derau memiliki pengaruh yang berbeda terhadap stabilitas QNN, meskipun probabilitas derau yang digunakan sama.

Tabel 1. Perbandingan Akurasi QNN Before Noise dan After Noise

No	Noise Level	Akurasi Bit-flip (%)	Akurasi Depolarizing (%)	Penurunan Akurasi Bit-flip (%)	Penurunan Akurasi Depolarizing (%)
1	0.00	85.25	85.25	0.00	0.00
2	0.05	75.00	75.75	10.25	9.50
3	0.10	67.25	68.50	18.00	16.7
4	0.15	52.25	62.20	33.00	22.75
5	0.20	52.00	58.25	33.25	27.00
6	0.25	49.25	53.35	36.00	32.00
7	0.30	47.25	45.75	38.00	39.50
8	0.35	48.75	44.50	36.50	40.75
9	0.40	47.50	52.75	37.75	32.50

Tabel 1 menyajikan hasil pengujian ketahanan Quantum Neural Network (QNN) terhadap dua jenis derau kuantum, yaitu bit flip noise dan depolarizing noise, pada berbagai tingkat noise (noise level). Setiap baris pada tabel merepresentasikan satu skenario pengujian dengan tingkat noise tertentu. Noise Level Menunjukkan probabilitas terjadinya derau kuantum yang disisipkan ke dalam rangkaian QNN. Nilai 0.00 berarti kondisi ideal tanpa noise (before noise), sedangkan nilai 0.40 menunjukkan kondisi dengan tingkat noise tinggi. Akurasi Bit-flip (%) Menunjukkan akurasi klasifikasi QNN setelah diberikan bit flip noise pada tingkat noise tertentu.

Akurasi Depolarizing (%) Menunjukkan akurasi klasifikasi QNN setelah diberikan depolarizing noise pada tingkat noise yang sama. Penurunan Akurasi Bit-flip (%) Menunjukkan selisih antara akurasi baseline (85.25%) dan akurasi setelah diberikan bit flip noise. Kolom ini menggambarkan seberapa besar degradasi performa yang terjadi akibat noise. Penurunan Akurasi Depolarizing (%) Menunjukkan selisih antara akurasi baseline dan akurasi setelah diberikan depolarizing noise.

Kondisi Baseline pada baris pertama yaitu pada noise level (0.00) bit flip maupun depolarizing noise menghasilkan akurasi yang sama, yaitu 85.25%, dengan penurunan akurasi 0.00%. Hal ini menunjukkan bahwa QNN bekerja optimal pada kondisi ideal tanpa gangguan derau kuantum. Nilai ini menjadi acuan utama (baseline) untuk mengukur dampak noise pada skenario berikutnya.

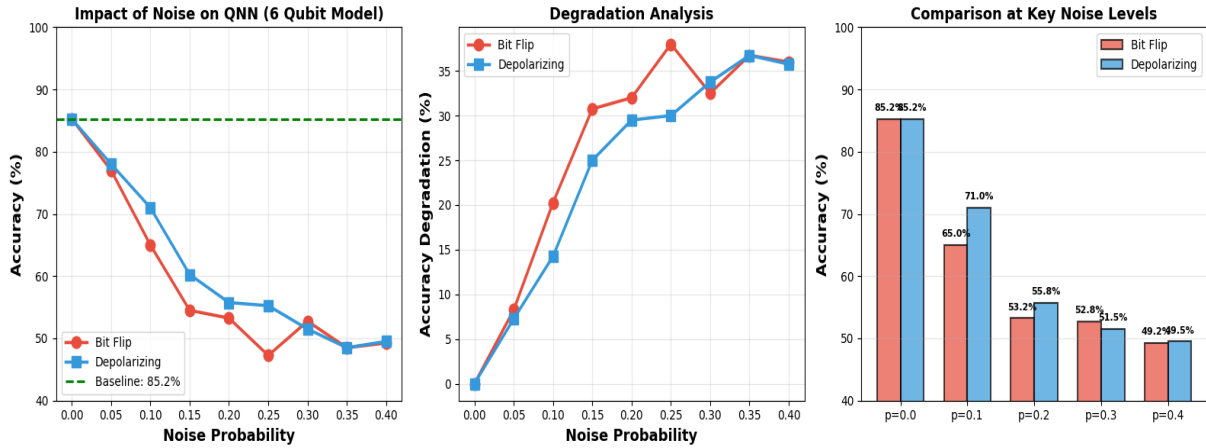
kemudian pada Noise level (0.05-0.10) Menunjukkan bahwa akurasi QNN mulai menurun menjadi 75.00% untuk bit flip dan 75.75% untuk depolarizing. Penurunan akurasi pada kedua noise masih relatif seimbang, yaitu sekitar 9–10%, menandakan bahwa pada tingkat noise rendah, kedua jenis derau memberikan dampak yang hampir sama. Ketika noise meningkat ke 0.10, penurunan performa menjadi lebih jelas. Akurasi bit flip turun menjadi 67.25%, sedangkan depolarizing masih sedikit lebih baik dengan 68.50%. Hal ini mengindikasikan bahwa depolarizing noise mulai menunjukkan karakteristik yang lebih toleran dibandingkan bit flip noise.

Pada rentang noise 0.15 hingga 0.25, perbedaan dampak kedua jenis noise menjadi semakin signifikan. Pada noise level 0.15, akurasi bit flip turun tajam hingga 52.25%, sedangkan depolarizing masih berada di atas 62.20%. Penurunan akurasi bit flip mencapai 33.00%, jauh lebih besar dibandingkan depolarizing yang hanya 22.75%. Pola serupa terlihat pada noise level 0.20 dan 0.25, di mana bit flip noise secara konsisten menyebabkan degradasi performa yang lebih besar. Hal ini menunjukkan bahwa mekanisme pembalikan qubit pada bit flip noise sangat mengganggu proses komputasi QNN.

Pada noise level tinggi, yaitu 0.30 hingga 0.40, akurasi kedua model berada di bawah 55%, yang menunjukkan bahwa QNN mulai kehilangan kemampuan klasifikasi secara andal. Pada noise level = 0.40, akurasi bit flip turun menjadi 47.50%, sedangkan depolarizing masih mampu mempertahankan akurasi 52.75%. Menariknya, pada noise level 0.30 dan 0.35, penurunan akurasi depolarizing sedikit lebih besar dibandingkan bit flip. Fluktuasi kecil yang muncul pada tingkat derau tinggi ( $p \geq 0.30$ ) tidak menunjukkan adanya peningkatan ketahanan model terhadap salah satu jenis derau, melainkan mengindikasikan bahwa QNN telah memasuki kondisi dekoherensi berat. Pada kondisi ini, informasi kuantum yang direpresentasikan oleh keadaan qubit telah mengalami degradasi signifikan, sehingga output model mendekati distribusi probabilitas acak.

Variasi performa yang terlihat pada rentang probabilitas derau tinggi kemungkinan besar disebabkan oleh variasi statistik dari hasil pengukuran kuantum serta keterbatasan jumlah sampel uji. Ketika model kehilangan kemampuan generalisasi, perbedaan kecil pada distribusi probabilitas hasil pengukuran dapat menghasilkan fluktuasi akurasi yang tampak tidak konsisten. Oleh karena itu, fluktuasi ini merepresentasikan batas operasional QNN pada lingkungan dengan tingkat derau tinggi di era NISQ, bukan keunggulan struktural dari salah satu jenis derau.

Hal ini menunjukkan bahwa pada tingkat noise tertentu, efek acak dari depolarizing noise dapat menjadi sangat destruktif, meskipun secara umum bit flip noise lebih merusak pada sebagian besar skenario.



**Gambar 7.** Grafik Degradasi Akurasi terhadap Tingkat Derau

Grafik akurasi QNN menunjukkan bagaimana performa model QNN 6 qubit berubah ketika diberi derau kuantum Bit-Flip dan Depolarizing. sumbu horizontal sebagai probabilitas noise (p) dan sumbu vertikal sebagai akurasi klasifikasi. Garis putus-putus hijau merepresentasikan akurasi baseline tanpa noise (p = 0) sebesar 85,2%, yang menunjukkan bahwa pada kondisi ideal QNN mampu mengklasifikasikan data dengan baik dan konsisten. Ketika noise mulai diinjeksi, terlihat bahwa akurasi menurun seiring meningkatnya nilai p, yang menandakan bahwa derau kuantum secara langsung mengganggu proses komputasi dan pengukuran qubit. Pada Bit-Flip noise, penurunan akurasi terjadi lebih tajam, terutama pada noise rendah hingga menengah, karena kesalahan pembalikan keadaan qubit ( $|0\rangle$  menjadi  $|1\rangle$  atau sebaliknya) secara langsung mengubah hasil pengukuran dan keputusan klasifikasi. Sementara itu, pada Depolarizing noise, penurunan akurasi bersifat lebih bertahap karena kesalahan terdistribusi secara acak pada berbagai operator Pauli, sehingga dampaknya terhadap keputusan klasifikasi tidak seagresif Bit-Flip. Grafik degradasi akurasi memperlihatkan bahwa selisih antara akurasi aktual dan baseline meningkat hampir linear seiring bertambahnya probabilitas noise, menegaskan bahwa penurunan performa yang terjadi merupakan dampak langsung dari derau kuantum, bukan kelemahan arsitektur model. Pada probabilitas noise tinggi ( $p \geq 0.3$ ), akurasi kedua jenis noise mendekati 50%, yang setara dengan tebakan acak pada klasifikasi biner, sehingga menunjukkan bahwa QNN kehilangan keunggulan komputasi kuantumnya dan berperilaku setara dengan model klasifikasi acak. Hal ini mencerminkan keterbatasan fundamental arsitektur QNN pada perangkat NISQ yang masih memiliki tingkat derau tinggi. Secara keseluruhan, grafik ini menegaskan bahwa baseline tanpa noise berperan sebagai titik acuan penting, dan setiap penurunan akurasi pada kondisi Bit-Flip dan Depolarizing mencerminkan tingkat sensitivitas dan keterbatasan ketahanan (robustness) QNN terhadap derau kuantum pada perangkat kuantum realistis. Pada kondisi ini, keadaan kuantum telah kehilangan korelasi informatif dengan data masukan, sehingga keluaran model cenderung berada pada zona klasifikasi acak. Dengan demikian, fluktuasi tersebut tidak merefleksikan keunggulan intrinsik salah satu jenis derau, melainkan menunjukkan keterbatasan QNN dalam mempertahankan kemampuan generalisasi pada tingkat noise ekstrem.

### 3.3 Pembahasan dan Keterkaitan dengan Hipotesis

Hipotesis penelitian ini menyatakan bahwa peningkatan tingkat derau kuantum akan menurunkan performa QNN, serta jenis derau yang berbeda akan menghasilkan pola degradasi performa yang berbeda. Berdasarkan hasil eksperimen, hipotesis tersebut dapat diterima. Temuan penelitian ini sejalan dengan penelitian sebelumnya yang menyebutkan bahwa derau kuantum merupakan faktor utama yang membatasi kinerja model kuantum pada era NISQ. Selain itu, hasil penelitian ini juga konsisten dengan studi yang menunjukkan bahwa klasifikasi MNIST menggunakan QNN sangat sensitif terhadap gangguan pada level gerbang kuantum. Hasil ini juga sejalan dengan studi eksperimental terbaru pada prosesor kuantum superkonduktor yang menunjukkan bahwa keberadaan noise inheren pada perangkat NISQ secara langsung membatasi robustness dan stabilitas QNN, meskipun dalam beberapa kasus noise tersebut dapat bertindak sebagai regularisasi implisit [17]. Namun demikian, penelitian ini memberikan kontribusi tambahan dengan membandingkan secara langsung dua jenis derau kuantum pada arsitektur QNN yang sama, sehingga pola ketahanan model dapat diamati dengan lebih jelas. Hasil ini



menunjukkan bahwa pemilihan model derau dan strategi mitigasi yang tepat menjadi faktor penting dalam pengembangan QNN yang lebih andal.

#### 4. KESIMPULAN

Penelitian ini menganalisis ketahanan Variational Quantum Neural Network (VQNN) terhadap derau kuantum pada tugas klasifikasi biner menggunakan subset dataset MNIST dalam konteks perangkat kuantum era Noisy Intermediate-Scale Quantum (NISQ). Hasil eksperimen menunjukkan bahwa pada kondisi ideal tanpa derau, VQNN dengan enam qubit dan satu lapisan variational mampu mencapai akurasi pengujian sebesar 85,25%, yang mengindikasikan bahwa arsitektur yang digunakan dapat merepresentasikan pola data citra secara efektif. Namun, ketika derau kuantum disisipkan ke dalam rangkaian, performa model mengalami degradasi yang signifikan seiring dengan meningkatnya probabilitas derau. Pada tingkat derau tinggi ( $p \geq 0,30$ ), akurasi klasifikasi menurun hingga mendekati ambang klasifikasi acak (~50%), yang menunjukkan bahwa model kehilangan kemampuan generalisasi akibat dekoherensi kuantum yang berat. Secara komparatif, bit flip noise memberikan dampak degradasi performa yang lebih tajam dibandingkan depolarizing noise pada sebagian besar tingkat derau, karena mekanisme pembalikan keadaan qubit secara langsung merusak informasi kuantum yang telah dipelajari oleh model. Temuan ini menegaskan bahwa derau kuantum merupakan faktor pembatas utama dalam implementasi VQNN pada era NISQ, serta menunjukkan bahwa pengembangan arsitektur yang lebih robust dan penerapan teknik mitigasi derau menjadi kebutuhan penting agar QNN dapat diterapkan secara lebih andal pada perangkat kuantum nyata di masa mendatang.

#### REFERENCES

- [1] M. Das and T. Bolisetti, "Variational Quantum Neural Networks (VQNNs) in Image Classification," Mar. 2023, [Online]. Available: <http://arxiv.org/abs/2303.05860>
- [2] S. Sajadimanesh, H. Aghae Rad, J. Paul Latyr Faye, and E. Atoofian, "NR-QNN: Noise-Resilient Quantum Neural Network," IEEE Access, vol. 13, pp. 40185–40197, 2025, doi: 10.1109/ACCESS.2025.3546956.
- [3] M. Vandromme and M. Tsuji, "Post-Variational Quantum Neural Networks on a Hybrid HPC-QC System," Association for Computing Machinery (ACM), Nov. 2025, pp. 1816–1823. doi: 10.1145/3731599.3767540.
- [4] T. Ahmed, M. Kashif, A. Marchisio, and M. Shafique, "A comparative analysis and noise robustness evaluation in quantum neural networks," Sci. Rep., vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-17769-6.
- [5] G. González-García, J. I. Cirac, and R. Trivedi, "Pauli path simulations of noisy quantum circuits beyond average-case," Quantum, vol. 9, 2025, doi: 10.22331/q-2025-05-05-1730.
- [6] Z. Li, T. Xiao, X. Deng, G. Zeng, and W. Li, "Optimizing Variational Quantum Neural Networks Based on Collective Intelligence," Mathematics, vol. 12, no. 11, Jun. 2024, doi: 10.3390/math12111627.
- [7] M. U. Khan, M. A. Kamran, W. R. Khan, M. M. Ibrahim, M. U. Ali, and S. W. Lee, "Error Mitigation in the NISQ Era: Applying Measurement Error Mitigation Techniques to Enhance Quantum Circuit Performance," Mathematics, vol. 12, no. 14, Jul. 2024, doi: 10.3390/math12142235.
- [8] Y. Ding, S. Zhang, X. Li, Y. Chang, and L. Yan, "Noise Mitigation An Efficient Approach for Quantum Convolutional Neural Networks to Enhance Performance in NISQ," Jul. 03, 2024. doi: 10.21203/rs.3.rs-4594670/v1.
- [9] D. Ranga, S. Prajapat, Z. Akhtar, P. Kumar, and A. V. Vasilakos, "Hybrid Quantum-Classical Neural Networks for Efficient MNIST Binary Image Classification," Mathematics, vol. 12, no. 23, Dec. 2024, doi: 10.3390/math12233684.
- [10] C. Long, M. Huang, X. Ye, Y. Futamura, and T. Sakurai, "Hybrid quantum-classical-quantum convolutional neural networks," Sci. Rep., vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-13417-1.
- [11] Y. Yang et al., "Hybrid Classical Quantum Neural Network with High Adversarial Robustness," 2024.
- [12] D. García-Martín, M. Larocca, and M. Cerezo, "Effects of noise on the overparametrization of quantum neural networks," Phys. Rev. Res., vol. 6, no. 1, Jan. 2024, doi: 10.1103/PhysRevResearch.6.013295.
- [13] N. Ji, R. Bao, Z. Chen, Y. Yu, and H. Ma, "Hybrid Quantum Neural Network Image Anti-Noise Classification Model Combined with Error Mitigation," Applied Sciences (Switzerland), vol. 14, no. 4, Feb. 2024, doi: 10.3390/app14041392.
- [14] P. S. S. Sein, M. Cañizo, and R. Orús, "Image classification with rotation-invariant variational quantum circuits," Phys. Rev. Res., vol. 7, no. 1, Jan. 2025, doi: 10.1103/PhysRevResearch.7.013082.
- [15] J. Song, B. Lu, L. Liu, and C. Wang, "Noisy Quantum Channel Characterization Using Quantum Neural Networks," Electronics (Switzerland), vol. 12, no. 11, Jun. 2023, doi: 10.3390/electronics12112430.
- [16] D. Winderl, N. Franco, and J. M. Lorenz, "Quantum neural networks under depolarization noise: exploring white-box attacks and defenses," Quantum Mach. Intell., vol. 6, no. 2, Dec. 2024, doi: 10.1007/s42484-024-00208-6.
- [17] H.-F. Zhang et al., "Experimental robustness benchmark of quantum neural network on a superconducting quantum processor," May 2025, [Online]. Available: <http://arxiv.org/abs/2505.16714>