

Analisis Perbandingan ANN dan Hybrid QNN pada Klasifikasi Multikarakteristik Data

DOI: <http://dx.doi.org/10.35889/jutisi.v15i2.3485>

Creative Commons License 4.0 (CC BY – NC)



Kharisteas Josan Sedi^{1*}, Sunneng Sandino Berutu², Aninda Astuti³

Informatika, Universitas Kristen Immanuel, Yogyakarta, Indonesia

*e-mail *Corresponding Author*: kharisteas.josan.s@mail.ukrim.ac.id

Abstract

The rapid advancement of machine learning has driven the exploration of various computational models to address classification problems across datasets with diverse characteristics. This study aimed to compare the performance of Artificial Neural Network (ANN) and Hybrid Quantum Neural Network (Hybrid QNN) under controlled experimental conditions. Three benchmark datasets, namely Red Wine Quality, Banknote Authentication, and Leukemia Gene Expression, were used with a training and test data split of 80:20. The evaluation was conducted using accuracy, precision, recall, F1-score, and computational time. The results showed that on the Gene Expression Leukemia dataset, Hybrid QNN achieved an accuracy of 0.9333, significantly outperforming ANN, which obtained 0.6111. Conversely, ANN demonstrated competitive performance and higher computational efficiency on low- and medium-dimensional datasets. These findings indicate that the advantages of Hybrid QNN are contextual and strongly dependent on data characteristics.

Keywords: *Artificial Neural Network; Hybrid Quantum Neural Network; classification; machine learning*

Abstrak

Perkembangan pesat pembelajaran mesin telah mendorong eksplorasi berbagai model komputasi untuk menyelesaikan permasalahan klasifikasi pada data dengan karakteristik yang beragam. Penelitian ini bertujuan untuk membandingkan kinerja *Artificial Neural Network* (ANN) dan *Hybrid Quantum Neural Network* (Hybrid QNN) dalam kondisi eksperimen yang terkontrol. Tiga *dataset* acuan digunakan, yaitu *Red Wine Quality*, *Banknote Authentication*, dan *Gene Expression Leukemia*, dengan pembagian data latih dan uji sebesar 80:20. Evaluasi dilakukan menggunakan metrik akurasi, *precision*, *recall*, *F1-score*, serta waktu komputasi. Hasil eksperimen menunjukkan bahwa pada *dataset Gene Expression Leukemia*, Hybrid QNN mencapai akurasi 0,9333, jauh lebih tinggi dibandingkan ANN sebesar 0,6111. Sebaliknya, ANN menunjukkan performa yang kompetitif dan lebih efisien pada *dataset* berdimensi rendah hingga menengah. Temuan ini menunjukkan bahwa keunggulan Hybrid QNN bersifat kontekstual dan bergantung pada karakteristik data.

Kata kunci: *Artificial Neural Network; Hybrid Quantum Neural Network; klasifikasi; machine learning*

1. Pendahuluan

Perkembangan pesat pembelajaran mesin (*machine learning*) telah memainkan peran penting dalam menyelesaikan berbagai permasalahan klasifikasi pada data dengan tingkat kompleksitas yang semakin meningkat. Meningkatnya ketersediaan data dari berbagai domain, seperti keuangan, industri, dan bioinformatika, mendorong kebutuhan akan model klasifikasi yang tidak hanya akurat, tetapi juga mampu menangani karakteristik data yang beragam, termasuk data berdimensi tinggi dan data dengan jumlah sampel terbatas. Dalam konteks ini, pemilihan model komputasi yang tepat menjadi faktor krusial untuk memperoleh performa klasifikasi yang optimal dan efisien.

Artificial Neural Network (ANN) merupakan salah satu pendekatan pembelajaran mesin yang paling banyak digunakan dan telah menunjukkan keberhasilan signifikan dalam berbagai aplikasi, seperti pengenalan pola, visi komputer, dan analisis data kompleks [1], [2]. Kemampuan ANN dalam memodelkan hubungan non-linear melalui lapisan tersembunyi menjadikannya sangat efektif pada data berdimensi rendah hingga menengah. Namun, pada permasalahan dengan karakteristik *high-dimensional*, *low-sample size*, seperti pada data ekspresi gen, kinerja ANN konvensional cenderung menurun dan berpotensi mengalami *overfitting* akibat keterbatasan rasio jumlah sampel terhadap jumlah fitur [2], [3]. Kondisi ini menimbulkan tantangan dalam penerapan ANN secara umum pada berbagai jenis data dengan kompleksitas yang berbeda.


Seiring dengan berkembangnya komputasi kuantum, muncul pendekatan baru dalam pembelajaran mesin yang dikenal sebagai *Quantum Machine Learning* (QML), yang bertujuan memanfaatkan prinsip mekanika kuantum untuk meningkatkan kapasitas representasi dan pemrosesan data [4], [5]. Salah satu model yang banyak dikaji dalam QML adalah *Quantum Neural Network* (QNN), khususnya dalam bentuk *hybrid QNN* yang menggabungkan rangkaian kuantum parametrik dengan proses optimisasi klasik [6], [7]. Beberapa penelitian menunjukkan bahwa QNN memiliki potensi keunggulan representasi pada data dengan struktur kompleks melalui pemetaan fitur kuantum dan fenomena superposisi serta interferensi [8], [9]. Meskipun demikian, penerapan QNN dalam praktik masih menghadapi berbagai keterbatasan, antara lain waktu komputasi yang tinggi, keterbatasan perangkat keras kuantum era NISQ, serta permasalahan optimisasi seperti *barren plateau* yang dapat menghambat proses pelatihan [10], [11].

Berbagai penelitian terdahulu telah berupaya mengevaluasi performa ANN maupun QNN pada dataset tertentu, baik sintesis maupun *dataset* nyata [12], [8], [13]. Studi-studi tersebut menunjukkan bahwa QNN dapat mencapai performa kompetitif, bahkan unggul pada kondisi tertentu, namun hasil yang diperoleh sangat bergantung pada karakteristik data, desain rangkaian kuantum, dan strategi pelatihan yang digunakan. Di sisi lain, sebagian besar penelitian masih mengevaluasi ANN dan QNN secara terpisah atau pada satu jenis *dataset* saja, sehingga belum memberikan gambaran komprehensif mengenai perbandingan kinerja kedua pendekatan tersebut pada data dengan tingkat kompleksitas yang berbeda dalam satu kerangka eksperimen yang konsisten. Dengan demikian, masih terdapat celah penelitian berupa kurangnya kajian sistematis yang mengaitkan karakteristik *dataset* seperti jumlah fitur, jumlah sampel, dan kompleksitas data dengan kinerja ANN dan *hybrid QNN* secara langsung.

Berdasarkan celah penelitian tersebut, penelitian ini mengusulkan suatu *state of the art* berupa analisis perbandingan kinerja ANN dan *Hybrid Quantum Neural Network* pada permasalahan klasifikasi biner menggunakan beberapa *dataset* dengan karakteristik yang berbeda. Tiga *dataset* acuan digunakan, yaitu *Banknote Authentication* sebagai representasi data berdimensi rendah [14], *Red Wine Quality* sebagai data berdimensi menengah [15], dan *Gene Expression Leukemia* sebagai data berdimensi tinggi dengan jumlah sampel terbatas [3]. Pendekatan *hybrid* dipilih dengan mengintegrasikan ANN sebagai tahap *embedding* dan rangkaian kuantum parametrik sebagai komponen pemrosesan non-linear, sehingga diharapkan mampu memanfaatkan keunggulan masing-masing paradigma komputasi. Melalui pendekatan ini, penelitian diharapkan dapat memberikan kontribusi ilmiah berupa pemahaman yang lebih kontekstual mengenai kondisi penggunaan ANN dan *Hybrid QNN*, sekaligus menjadi dasar penelitian pada bidang pembelajaran mesin dan komputasi kuantum terapan.

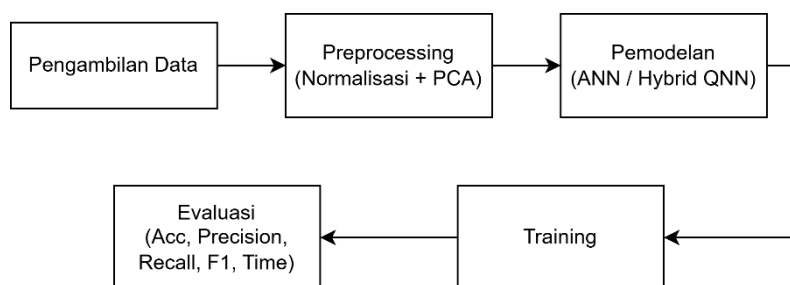
2. Metodologi

Metodologi penelitian ini dirancang untuk menjawab tujuan utama penelitian, yaitu membandingkan kinerja *Artificial Neural Network* (ANN) dan *Hybrid Quantum Neural Network* (Hybrid QNN) secara objektif dan terkontrol. Mengingat keunggulan pendekatan kuantum tidak bersifat universal dan secara signifikan bergantung pada karakteristik data, diperlukan rancangan metodologi yang mampu mengevaluasi kedua model pada kondisi yang setara. Oleh karena itu, penelitian ini menggunakan pendekatan eksperimen komparatif dengan menerapkan *pipeline* yang sama pada setiap model, mulai dari pemilihan *dataset*, pra-pemrosesan data, perancangan model, hingga evaluasi kinerja. Pendekatan ini dipilih untuk memastikan bahwa perbedaan hasil yang diperoleh dapat dikaitkan secara langsung dengan karakteristik model, bukan dengan perbedaan perlakuan eksperimen. Selain itu, penggunaan tahapan yang sistematis dan terdokumentasi bertujuan untuk memastikan bahwa penelitian dapat direproduksi serta memberikan dasar analisis yang kuat terhadap pertukaran antara akurasi dan waktu komputasi.



Gambar 1. Ilustrasi pemrosesan input pada *Artificial Neural Network*

Secara konseptual, ANN memproses data melalui mekanisme *feed-forward*, di mana setiap fitur masukan dikombinasikan secara linier menggunakan bobot tertentu dan dipetakan ke dalam ruang keluaran (output) melalui fungsi aktivasi. Ilustrasi tersebut ditunjukkan pada Gambar 1. Tahapan utama dalam penelitian ini meliputi pengambilan data, pra-pemrosesan data, perancangan model, proses pelatihan, serta evaluasi kinerja model, seperti yang diilustrasikan dalam Gambar 2.



Gambar 2. Tahapan penelitian

2.1. Pengambilan Data

Penelitian ini menggunakan tiga *dataset* yang umum digunakan dalam studi klasifikasi, yaitu *Banknote Authentication* (BA), *Red Wine Quality* (RWQ), dan *Gene Expression Leukemia* (GEL). *Dataset* BA dan RWQ diperoleh dari *UCI Machine Learning Repository*, sedangkan *dataset* GEL diperoleh dari Kaggle. Ketiga *dataset* tersebut dipilih karena memiliki karakteristik yang berbeda dari segi jumlah sampel, jumlah fitur, serta tingkat kompleksitas data, sehingga memungkinkan evaluasi performa model secara lebih komprehensif.

Dataset Banknote Authentication (BA) diperoleh dari *UCI Machine Learning Repository* [14]. *Dataset* ini merupakan hasil ekstraksi fitur dari citra uang kertas menggunakan transformasi wavelet, dengan tujuan klasifikasi keaslian uang. *Dataset* ini memiliki jumlah sampel yang relatif besar dengan jumlah fitur yang terbatas, sehingga sesuai untuk menguji performa model pada data berdimensi rendah hingga menengah.

Dataset Red Wine Quality (RWQ) juga diperoleh dari *UCI Machine Learning Repository* [15]. *Dataset* ini digunakan untuk memprediksi kualitas anggur merah berdasarkan sejumlah atribut fisikokimia, seperti keasaman, kadar alkohol, dan pH. *Dataset* ini memiliki jumlah fitur yang lebih banyak dibandingkan *Banknote Authentication*, namun masih berada dalam kategori data berdimensi menengah. Proses klasifikasi dilakukan dengan mengelompokkan nilai kualitas anggur ke dalam kelas tertentu sesuai dengan skenario eksperimen yang ditetapkan.

Dataset Gene Expression Leukemia (GEL) diperoleh dari Kaggle [3]. *Dataset* ini memiliki karakteristik yang berbeda, yaitu jumlah fitur yang secara signifikan besar dibandingkan jumlah sampel. *Dataset* ini merepresentasikan tingkat ekspresi gen pasien leukemia dengan dua kelas utama, yaitu *Acute Lymphoblastic Leukemia* (ALL) dan *Acute Myelogenous Leukemia* (AML). *Dataset* ini digunakan untuk menguji kemampuan model dalam menangani data berdimensi tinggi dengan ukuran sampel yang terbatas.

Seluruh *dataset* dibagi ke dalam data pelatihan dan data pengujian dengan rasio 80:20. Pembagian ini dilakukan secara konsisten pada ketiga *dataset* untuk memastikan perbandingan kinerja ANN dan Hybrid QNN dilakukan secara adil dan terkontrol.

2.2. Normalisasi Data

Seluruh *dataset* dinormalisasi menggunakan *StandardScaler* untuk memastikan distribusi fitur memiliki rerata nol dan variansi satu [1]. Secara matematis, standarisasi dinyatakan pada Persamaan (1) sebagai berikut, di mana μ merupakan nilai rerata dan σ adalah simpangan baku dari setiap fitur:

$$z_i = \frac{x_i - \mu}{\sigma} \quad (1)$$

Selanjutnya, reduksi dimensi dilakukan menggunakan Principal Component Analysis (PCA) untuk memproyeksikan data ke ruang berdimensi lebih rendah dengan mempertahankan variansi terbesar [16]. Proses PCA diawali dengan pembentukan matriks kovarians untuk merepresentasikan hubungan antar fitur, yang selanjutnya digunakan dalam dekomposisi eigen guna memperoleh komponen utama sebagai representasi baru data berdimensi lebih rendah.

$$\Sigma = \frac{1}{n-1} X^T X \quad (2)$$

Pada *dataset* BA dan RWQ, dilakukan reduksi dimensi awal menggunakan Principal Component Analysis (PCA) untuk mengurangi korelasi antar fitur, yang kemudian diikuti oleh seleksi fitur berbasis SelectKBest menggunakan uji ANOVA (*f_classif*). Pendekatan ini bertujuan untuk mempertahankan fitur yang paling diskriminatif terhadap kelas target.

Pada *dataset* GEL, PCA diterapkan secara langsung untuk mereduksi dimensi dari ribuan gen menjadi delapan komponen utama, dengan pertimbangan keterbatasan jumlah sampel dan stabilitas pelatihan model. Reduksi dimensi ini bertujuan untuk mengurangi risiko *overfitting* serta memungkinkan pemrosesan lanjutan oleh model ANN dan Hybrid QNN.

2.3. Model Artificial Neural Network (ANN)

Model ANN digunakan sebagai *baseline* pada setiap *dataset*. Untuk *dataset* BA dan RWQ, ANN dibangun dengan satu lapisan tersembunyi menggunakan fungsi aktivasi *ReLU* dan satu neuron keluaran dengan fungsi aktivasi sigmoid untuk klasifikasi biner. Jumlah neuron pada lapisan tersembunyi divariasikan untuk memperoleh konfigurasi terbaik berdasarkan performa evaluasi.

Secara matematis, proses pembelajaran pada ANN dapat direpresentasikan sebagai transformasi non-linear berlapis yang memetakan vektor masukan ke ruang keluaran melalui kombinasi bobot dan fungsi aktivasi.

1. *Feed-forward*:

$$z^{(l)} = W^{(l)} a^{(l-1)} + b^{(l)} \quad (3)$$

2. Aktivasi ReLU:

$$a^{(l)} = \max(0, z^{(l)}) \quad (4)$$

3. *Output sigmoid*:

$$\hat{y} = \sigma(z) \quad (5)$$

4. *Loss*:

$$\mathcal{L} = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \quad (6)$$

Pada persamaan tersebut, $W^{(l)}$ dan $b^{(l)}$ masing-masing merepresentasikan matriks bobot dan vektor bias pada lapisan ke- l , $a^{(l)}$ merupakan keluaran aktivasi lapisan ke- l , sedangkan \hat{y} adalah probabilitas keluaran hasil fungsi sigmoid.

Pada *dataset Gene Expression Leukemia*, digunakan ANN dengan dua lapisan tersembunyi berukuran 16 dan 8 neuron. Arsitektur ini dipilih untuk menangkap hubungan non-linear antar fitur hasil PCA yang masih bersifat kompleks. Seluruh model ANN dilatih

menggunakan *optimizer* Adam dengan fungsi loss binary *cross-entropy* dan mekanisme *early stopping* untuk mencegah *overfitting*. Waktu pelatihan dan evaluasi dicatat untuk keperluan analisis efisiensi komputasi.

2.4. Model Hybrid Quantum Neural Network (Hybrid QNN)

Hybrid Quantum Neural Network (Hybrid QNN) merupakan pendekatan pembelajaran mesin yang menggabungkan komputasi klasik dan kuantum dalam satu arsitektur terpadu. Pada pendekatan ini, sebagian proses pembelajaran dilakukan menggunakan rangkaian kuantum parametrik, sedangkan optimisasi parameter tetap dilakukan secara klasik. Model ini memungkinkan pemanfaatan kemampuan representasi ruang Hilbert kuantum tanpa sepenuhnya bergantung pada perangkat keras kuantum murni.

Secara umum, QNN direalisasikan dalam bentuk *Variational Quantum Circuit* (VQC), yang terdiri dari rangkaian kuantum parametrik dengan parameter yang dioptimalkan menggunakan algoritma klasik. Data klasik dipetakan ke keadaan kuantum melalui pemetaan fitur (*feature map*), kemudian diproses oleh ansatz *variational* sebelum dilakukan pengukuran untuk menghasilkan keluaran klasifikasi.

Secara matematis, Hybrid QNN direalisasikan dalam bentuk rangkaian kuantum parametrik yang memetakan data klasik ke keadaan kuantum dan mengoptimalkan parameter *variational* untuk meminimalkan fungsi biaya.

1. *Feature Map*:

$$|\phi(x)\rangle = U_\phi(x)|0\rangle \quad (7)$$

2. *Variational Circuit*:

$$|\psi(\theta)\rangle = U(\theta)|\phi(x)\rangle \quad (8)$$

3. *Measurement*:

$$\hat{y} = \langle\psi(\theta)|\hat{O}|\psi(\theta)\rangle \quad (9)$$

Pada formulasi tersebut, $U_\phi(x)$ merepresentasikan rangkaian pemetaan fitur klasik ke keadaan kuantum, $U(\theta)$ adalah rangkaian *variational* dengan parameter yang dioptimalkan secara klasik, \hat{O} merupakan operator observabel yang diukur, dan \hat{y} menyatakan nilai ekspektasi hasil pengukuran yang digunakan sebagai keluaran klasifikasi.

Pendekatan Hybrid QNN pada penelitian ini menggabungkan ANN sebagai *feature embedding* dan *Variational Quantum Classifier* (VQC) sebagai pengklasifikasi kuantum. ANN *embedding* digunakan untuk memetakan data klasik ke dalam representasi berdimensi rendah yang sesuai dengan jumlah qubit yang tersedia. Dimensi *embedding* secara langsung menentukan jumlah qubit yang digunakan pada model kuantum.

Pada *dataset* BA, ANN *embedding* menggunakan 4 dan 8 neuron. *Dataset* RWQ menggunakan *embedding* berukuran 4 neuron, sedangkan *dataset* GEL menggunakan *embedding* berukuran 8 neuron setelah reduksi PCA. Hasil *embedding* kemudian dinormalisasi menggunakan *MinMaxScaler* dan dilewatkan melalui fungsi aktivasi hiperbolik tangensial (*tanh*) untuk meningkatkan stabilitas representasi sebelum diproses oleh rangkaian kuantum.

2.5. Pelatihan Model

Model kuantum dibangun menggunakan *PauliFeatureMap* dengan kombinasi operator *Pauli* X dan Z sebagai pemetaan fitur klasik ke keadaan kuantum. Rangkaian *variational* menggunakan *EfficientSU2* ansatz dengan berbagai konfigurasi jumlah repetisi dan pola *entanglement*, termasuk full dan linear, sesuai dengan karakteristik masing-masing *dataset*.

Optimasi parameter rangkaian kuantum dilakukan menggunakan algoritma optimasi klasik, yaitu COBYLA, SLSQP, dan SPSA, dengan batas iterasi maksimum sebanyak 300. Seluruh eksperimen kuantum dieksekusi menggunakan *Sampler* dengan jumlah pengukuran sebanyak 2048 *shots* untuk memperoleh estimasi probabilitas keluaran yang stabil. Fungsi *loss* yang digunakan adalah *cross-entropy*, dengan label target direpresentasikan dalam bentuk *one-hot encoding*.

2.6. Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan untuk mengukur kemampuan *Artificial Neural Network* (ANN) dan *Hybrid Quantum Neural Network* (Hybrid QNN) dalam menyelesaikan permasalahan klasifikasi biner pada masing-masing *dataset*. Seluruh *dataset* dibagi secara konsisten menjadi data latih sebesar 80% dan data uji sebesar 20% menggunakan teknik *stratified sampling* untuk menjaga proporsi kelas.

Pada tahap pelatihan (80%), model ANN dan Hybrid QNN dilatih untuk mempelajari pola hubungan antara fitur masukan dan label kelas. Selanjutnya, pada tahap pengujian (20%), model digunakan untuk memprediksi label kelas dari data yang tidak pernah dilihat sebelumnya. Hasil prediksi ini kemudian dibandingkan dengan label aktual untuk mengevaluasi performa klasifikasi.

Evaluasi dilakukan menggunakan beberapa metrik performa yang umum digunakan pada permasalahan klasifikasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*, serta waktu komputasi total yang mencakup proses pelatihan dan pengujian model.

Accuracy digunakan untuk mengukur proporsi prediksi yang benar terhadap seluruh data uji dan dirumuskan sebagai:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

Precision mengukur ketepatan model dalam memprediksi kelas positif, yang didefinisikan sebagai:

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

Recall menunjukkan kemampuan model dalam mengenali seluruh data yang termasuk dalam kelas positif dan dirumuskan sebagai:

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

F1-score merupakan rata-rata harmonik antara *precision* dan *recall*, yang digunakan untuk memberikan ukuran performa yang lebih seimbang, terutama pada data dengan distribusi kelas yang tidak seimbang. *F1-score* dirumuskan sebagai:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (13)$$

Penggunaan metrik-metrik tersebut telah banyak diterapkan dalam penelitian sebelumnya pada bidang pembelajaran mesin klasik maupun *quantum machine learning* untuk mengevaluasi performa model klasifikasi [6], [7], [8].

Seluruh eksperimen dilakukan pada lingkungan komputasi yang sama untuk menjamin konsistensi hasil. Model ANN dan Hybrid QNN dibandingkan berdasarkan konfigurasi terbaik pada masing-masing *dataset* untuk menilai keunggulan dan keterbatasan pendekatan kuantum hibrid dibandingkan metode klasik, seperti yang dijelaskan pada Tabel 1.

Tabel 1. Spesifikasi model

<i>Dataset</i>	<i>Model</i>	<i>Preprocessing</i>	<i>Reduksi Fitur</i>	<i>Arsitektur Model</i>	<i>Optimizer</i>	<i>Epoch / Iterasi</i>
<i>Banknote Authentication</i>	ANN	<i>StandardScaler</i>	PCA(4) + <i>SelectKBest</i> (4)	1 <i>Hidden Layer</i> (6 neuron, ReLU) + <i>Output</i> (Sigmoid)	Adam	80
	Hybrid QNN	<i>StandardScaler</i> → <i>MinMaxScaler</i>	ANN <i>Embedding</i> (4 neuron)	<i>PauliFeatureMap</i> (<i>reps</i> =1, <i>pauli</i> ={X,Z}) + <i>EfficientSU2</i> (<i>reps</i> =2, <i>full</i>)	SLSQP	300

<i>Dataset</i>	<i>Model</i>	<i>Preprocessing</i>	<i>Reduksi Fitur</i>	<i>Arsitektur Model</i>	<i>Optimizer</i>	<i>Epoch / Iterasi</i>
Red Wine Quality	ANN	<i>StandardScaler</i>	PCA(6) + <i>SelectKBest</i> (4)	1 <i>Hidden Layer</i> (6 neuron, ReLU) + <i>Output</i> (Sigmoid)	Adam	80
	Hybrid QNN	<i>StandardScaler</i> → <i>MinMaxScaler</i> → <i>tanh</i>	ANN <i>Embedding</i> (4 neuron)	<i>PauliFeatureMap</i> (<i>reps</i> =1) + <i>EfficientSU2</i> (<i>reps</i> =1, full)	COBYLA	300
Gene Expression	ANN	<i>StandardScaler</i>	PCA(8)	2 <i>Hidden Layers</i> (16, 8 neuron, ReLU) + <i>Output</i> (Sigmoid)	Adam	150
	Hybrid QNN	<i>StandardScaler</i> → PCA(8) → <i>MinMaxScaler</i> → <i>tanh</i>	ANN <i>Embedding</i> (8 neuron)	<i>PauliFeatureMap</i> (<i>reps</i> =2, <i>pauli</i> ={X,Z}) + <i>EfficientSU2</i> (<i>reps</i> =1, full)	COBYLA	300

Pada pendekatan *Hybrid Quantum Neural Network* (Hybrid QNN), fitur tidak langsung dimasukkan ke model kuantum, melainkan terlebih dahulu dipetakan menggunakan *Artificial Neural Network* (ANN) sebagai *feature embedding*. Dimensi *embedding* menentukan jumlah qubit yang digunakan pada model kuantum. Pendekatan ini bertujuan untuk menurunkan kompleksitas input sekaligus mempertahankan karakteristik non-linear data sebelum diproses oleh rangkaian kuantum.

3. Hasil dan Pembahasan

Bagian ini menyajikan hasil eksperimen dan pembahasan komprehensif mengenai perbandingan kinerja *Artificial Neural Network* (ANN) dan *Hybrid Quantum Neural Network* (Hybrid QNN) pada tiga *dataset* dengan karakteristik yang berbeda, yaitu *Banknote Authentication*, *Red Wine Quality*, dan *Gene Expression Leukemia*. Evaluasi dilakukan untuk menilai performa klasifikasi serta efisiensi komputasi dari kedua pendekatan pada kondisi eksperimen yang setara.

Seluruh *dataset* dibagi menjadi data latih sebesar 80% dan data uji sebesar 20%. Data latih digunakan untuk proses pembelajaran model, sedangkan data uji digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data yang tidak terlibat dalam proses pelatihan. Sebelum menyajikan metrik evaluasi kuantitatif, bagian ini terlebih dahulu memberikan gambaran mengenai hasil klasifikasi yang dihasilkan oleh model sebagai dasar perhitungan performa.

3.1 Gambaran Umum Proses Klasifikasi

Pada penelitian ini, proses klasifikasi dilakukan terhadap data numerik yang telah melalui tahapan pra-proses. Pada *dataset Red Wine Quality* dan *Banknote Authentication*, data digunakan dalam bentuk fitur numerik terstandarisasi. Sementara itu, pada *dataset Gene Expression Leukemia* yang memiliki dimensi sangat tinggi, diterapkan reduksi dimensi menggunakan *Principal Component Analysis* (PCA), kemudian dilanjutkan dengan pemetaan *embedding* menggunakan *Artificial Neural Network* (ANN) sebelum diklasifikasikan oleh model Hybrid QNN. Output klasifikasi berupa prediksi kelas biner, yang kemudian dibandingkan dengan label kelas asli untuk mengevaluasi performa model.

3.2 Contoh Hasil Klasifikasi Model

3.2.1 Contoh Hasil Klasifikasi pada *Dataset Banknote Authentication* (ANN)

Tabel berikut menyajikan contoh hasil klasifikasi model ANN pada *dataset Banknote Authentication*, yang mencakup empat fitur numerik hasil ekstraksi citra, label asli, serta hasil prediksi model.

Tabel 2. Contoh hasil klasifikasi ANN pada *dataset Banknote Authentication*

	F1	F2	F3	F4	Label Asli	Prediksi Model
0	1.070963	0.341393	0.300536	0.409852	0	0
1	0.210777	-0.575507	-0.510760	-0.223793	1	1
2	2.611080	-2.122987	0.751551	-0.553671	0	0
3	-0.290999	0.421313	-0.921484	-0.135470	1	1
4	-2.095004	-0.514471	-0.028596	-0.271463	1	1
5	2.192166	-0.990693	0.629678	-1.179817	1	1
6	0.768623	0.855663	0.103046	0.356026	0	0
7	1.448836	1.172159	0.205923	0.166503	0	0
8	1.020748	-1.461618	0.040447	1.033633	0	0
9	-4.105438	-1.036561	0.822341	0.241743	1	1

Dari tabel tersebut terlihat bahwa sebagian besar sampel diklasifikasikan dengan benar oleh model ANN. Hal ini mengindikasikan bahwa pemisahan kelas pada *dataset Banknote Authentication* relatif jelas, sehingga ANN mampu mempelajari batas keputusan secara efektif bahkan dengan arsitektur yang sederhana.

3.2.2 Contoh Hasil Klasifikasi pada *Dataset Gene Expression Leukemia (Hybrid QNN)*

Tabel berikut menampilkan contoh hasil klasifikasi Hybrid QNN pada *dataset Gene Expression Leukemia*. Fitur yang digunakan merupakan hasil *embedding* ANN berdimensi rendah yang kemudian diproses oleh *Variational Quantum Circuit (VQC)*.

Tabel 3. Contoh hasil klasifikasi Hybrid QNN pada *dataset Gene Expression Leukemia*

	E1	E2	E3	E4	E5	E6	E7	E8	Label Asli	Prediksi Model
0	-0.761	-0.761	-0.761	-0.761	-0.530	-0.761	-0.761	-0.761	0	0
1	-0.630	-0.761	-0.616	-0.761	-0.685	-0.761	-0.761	-0.532	0	0
2	-0.761	-0.725	-0.754	-0.678	-0.761	-0.761	-0.054	-0.761	0	1
3	-0.761	-0.761	-0.761	-0.670	-0.761	-0.612	-0.761	-0.398	0	0
4	-0.636	-0.593	-0.254	-0.613	-0.644	-0.190	-0.636	-0.761	1	1
5	-0.724	-0.134	-0.761	-0.761	-0.761	-0.761	0.539	-0.760	0	1
6	-0.600	-0.761	-0.761	-0.761	-0.254	-0.761	-0.761	-0.761	0	0
7	-0.761	-0.709	-0.761	-0.761	-0.761	-0.761	-0.044	-0.626	0	1

Berdasarkan contoh tersebut, dapat diamati bahwa model Hybrid QNN secara eksplisit menghasilkan keputusan klasifikasi pada setiap sampel data. Perbedaan antara label kelas asli dan prediksi model pada beberapa sampel menunjukkan adanya kesalahan klasifikasi, yang selanjutnya dianalisis secara kuantitatif menggunakan metrik evaluasi performa.

3.3. Evaluasi Performa Kuantitatif

Evaluasi performa dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score, serta waktu komputasi sebagai indikator efisiensi. Seluruh metrik disajikan dalam bentuk tabel seperti yang ditunjukkan pada Tabel 4.

Tabel 4. Perbandingan kinerja ANN dan Hybrid QNN pada ketiga *dataset*

<i>Dataset</i>	<i>Model</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Time(detik)</i>
RWQ	ANN	0,7406	0,7588	0,7544	0,7566	20,08
	Hybrid QNN	0,7438	0,7259	0,8363	0,7772	621,70
BA	ANN	1,00	1,00	1,00	1,00	23,76
	Hybrid QNN	0,9855	0,9917	0,9754	0,9835	4208,08
GEL	ANN	0,6111	0,4286	0,5	0,4615	5,6283
	Hybrid QNN	0,9333	1,00	0,8	0,888	222,297

3.4 Analisis Teknis per *Dataset*

3.4.1 *Dataset Red Wine Quality*

Dataset Red Wine Quality memiliki jumlah sampel yang relatif besar (1.599) dengan jumlah fitur menengah (11 fitur). Pada kondisi ini, ANN mampu mempelajari hubungan non-linear antar fitur secara efektif, yang tercermin dari nilai *accuracy* dan *F1-score* yang stabil antara data latih dan data uji.

Hybrid QNN menunjukkan performa yang sebanding, namun tidak memberikan peningkatan yang signifikan dibandingkan ANN. Secara teknis, hal ini dapat dijelaskan karena kompleksitas data masih berada dalam kapasitas representasi ANN konvensional, sehingga keunggulan representasi kuantum belum termanfaatkan secara optimal. Selain itu, overhead komputasi pada proses optimasi parameter kuantum menyebabkan waktu komputasi Hybrid QNN menjadi jauh lebih besar dibandingkan ANN.

3.4.2 *Dataset Banknote Authentication*

Dataset Banknote Authentication memiliki jumlah sampel yang terbilang besar (1.372) dengan jumlah fitur yang sangat rendah (4) dan pemisahan kelas yang jelas. Dalam kondisi ini, ANN menunjukkan performa yang hampir sempurna pada seluruh metrik evaluasi.

Hybrid QNN juga menghasilkan performa yang tinggi, namun sedikit lebih rendah dibandingkan ANN. Secara teknis, hal ini menunjukkan bahwa ketika struktur data sederhana dan batas keputusan mudah dipelajari, model berbasis kuantum tidak memberikan keuntungan tambahan. Bahkan, kompleksitas sirkuit kuantum justru meningkatkan waktu komputasi secara signifikan tanpa diimbangi peningkatan performa klasifikasi.

3.4.3 *Dataset Gene Expression Leukemia*

Dataset Gene Expression Leukemia memiliki karakteristik high-dimensional, low-sample size, dengan lebih dari 7.000 fitur dan hanya 72 sampel. Pada kondisi ini, ANN konvensional menunjukkan keterbatasan dalam melakukan generalisasi, meskipun telah dilakukan reduksi dimensi menggunakan PCA. Hal ini tercermin dari nilai *accuracy* dan *F1-score* yang relatif rendah.

Sebaliknya, Hybrid QNN menunjukkan peningkatan performa yang sangat signifikan. Secara teknis, hal ini disebabkan oleh kemampuan sirkuit kuantum dalam memetakan data ke ruang Hilbert berdimensi tinggi melalui encoding kuantum. Representasi ini memungkinkan model menangkap korelasi non-linear kompleks yang sulit dipelajari oleh ANN konvensional pada kondisi data terbatas.

Namun demikian, peningkatan performa ini disertai dengan waktu komputasi yang jauh lebih besar, yang menjadi keterbatasan utama dalam penerapan praktis Hybrid QNN pada perangkat saat ini.

3.5 Pembahasan

Pembahasan pada penelitian ini menyoroti perbedaan karakteristik kerja antara *Artificial Neural Network* (ANN) dan *Hybrid Quantum Neural Network* (Hybrid QNN) ketika diterapkan pada *dataset* dengan tingkat kompleksitas yang berbeda. Hasil eksperimen menunjukkan bahwa ANN memiliki keunggulan utama dari sisi efisiensi komputasi dan stabilitas pelatihan, khususnya pada *dataset* dengan dimensi fitur rendah hingga menengah dan jumlah sampel yang relatif besar. Pada kondisi tersebut, ANN mampu membangun batas keputusan non-linear secara efektif melalui optimasi bobot berbasis gradien, tanpa memerlukan representasi fitur yang kompleks.

Sebaliknya, Hybrid QNN menunjukkan karakteristik kerja yang berbeda pada *dataset* dengan dimensi fitur sangat tinggi dan jumlah sampel yang terbatas. Melalui pemetaan data ke

ruang Hilbert berdimensi tinggi menggunakan *Variational Quantum Circuit* (VQC), model Hybrid QNN memiliki kapasitas representasi yang lebih ekspresif dibandingkan ANN konvensional. Pendekatan ini memungkinkan model untuk menangkap korelasi non-linear kompleks yang sulit dipelajari oleh model klasik pada kondisi high-dimensional, low-sample size, sebagaimana juga dilaporkan pada penelitian sebelumnya terkait pembelajaran mesin kuantum hybrid [8], [12].

Peningkatan performa Hybrid QNN pada *dataset Gene Expression Leukemia* sejalan dengan studi yang menyatakan bahwa sirkuit kuantum parametrik memiliki kemampuan representasi yang kuat melalui superposisi dan interferensi kuantum, sehingga berpotensi meningkatkan kemampuan generalisasi pada data berdimensi tinggi [5], [6]. Namun demikian, keunggulan tersebut masih diimbangi oleh keterbatasan praktis, terutama dari sisi waktu komputasi. Proses optimasi parameter kuantum bersifat iteratif dan memerlukan evaluasi sirkuit berulang kali, sehingga menyebabkan waktu pelatihan Hybrid QNN menjadi jauh lebih besar dibandingkan ANN, khususnya ketika dijalankan pada simulator kuantum klasik.

Kontribusi utama penelitian ini terletak pada penyajian analisis empiris yang menekankan bahwa efektivitas model pembelajaran mesin sangat dipengaruhi oleh karakteristik data yang digunakan. Hasil penelitian ini menunjukkan bahwa ANN tetap menjadi solusi yang efisien dan praktis untuk permasalahan klasifikasi dengan kompleksitas rendah hingga menengah, sementara Hybrid QNN menunjukkan potensi yang lebih besar pada permasalahan berdimensi tinggi yang membutuhkan representasi fitur yang lebih ekspresif. Dengan demikian, penelitian ini memperkuat temuan sebelumnya mengenai peran pendekatan hybrid kuantum-klasik sebagai alternatif menjanjikan dalam pengembangan *machine learning* kuantum di masa mendatang [4], [8].

4. Simpulan

Penelitian ini telah membandingkan kinerja model *Artificial Neural Network* (ANN) dan *Hybrid Quantum Neural Network* (Hybrid QNN) pada tiga *dataset* dengan karakteristik yang berbeda, yaitu *Red Wine Quality*, *Banknote Authentication*, dan *Gene Expression Leukemia*. Evaluasi dilakukan menggunakan metrik klasifikasi serta waktu komputasi untuk memperoleh gambaran menyeluruh mengenai keunggulan dan keterbatasan masing-masing pendekatan.

Hasil penelitian menunjukkan bahwa ANN memiliki kinerja yang sangat baik dan efisien pada *dataset* dengan kompleksitas rendah hingga menengah, seperti *Red Wine Quality* dan *Banknote Authentication*. Pada *dataset* tersebut, ANN mampu mencapai performa klasifikasi yang tinggi dengan waktu komputasi yang relatif singkat, sehingga lebih praktis untuk diterapkan pada permasalahan klasifikasi dengan jumlah fitur terbatas dan distribusi data yang jelas.

Sebaliknya, pada *dataset Gene Expression Leukemia* yang memiliki karakteristik *high-dimensional*, *low-sample size*, Hybrid QNN menunjukkan keunggulan performa yang signifikan dibandingkan ANN. Peningkatan akurasi dan metrik klasifikasi lainnya mengindikasikan bahwa pendekatan kuantum memiliki potensi dalam merepresentasikan pola kompleks pada data berdimensi tinggi yang kurang optimal ditangani oleh ANN konvensional.

Meskipun demikian, penggunaan Hybrid QNN masih menghadapi keterbatasan utama, yaitu waktu komputasi yang jauh lebih besar dibandingkan ANN serta potensi *overfitting* akibat jumlah sampel yang terbatas. Oleh karena itu, pemilihan model pembelajaran mesin, baik konvensional maupun berbasis kuantum, perlu disesuaikan dengan karakteristik *dataset* dan kebutuhan aplikasi.

Secara keseluruhan, penelitian ini menegaskan bahwa ANN lebih sesuai untuk permasalahan klasifikasi yang menuntut efisiensi komputasi, sedangkan Hybrid QNN memiliki potensi yang menjanjikan untuk diaplikasikan pada data berdimensi tinggi. Penelitian selanjutnya dapat diarahkan pada eksplorasi arsitektur QNN yang lebih efisien, pemanfaatan skema encoding kuantum yang berbeda, serta pengujian pada *dataset* yang lebih besar untuk memperkuat validitas temuan.

Daftar Referensi

- [1] K. G. Kim, "Book Review: Deep Learning," *Healthc. Inform. Res.*, vol. 22, no. 4, pp. 351-360, 2016, doi: 10.4258/hir.2016.22.4.351.
- [2] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, 2015, doi: 10.1038/nature14539.

- [3] T. R. Golub et al., "Molecular classification of cancer: Class discovery and class prediction by gene expression monitoring," *Science*, vol. 286, no. 5439, pp. 531–537, 1999, doi: 10.1126/science.286.5439.531.
- [4] V. Dunjko and H. J. Briegel, "*Machine learning* & artificial intelligence in the quantum domain," arXiv:1709.02779, 2017. [Online]. Available: <https://arxiv.org/abs/1709.02779>
- [5] J. Biamonte, P. Wittek, N. Pancotti, P. Rebentrost, N. Wiebe, and S. Lloyd, "Quantum *machine learning*," *Nature*, vol. 549, no. 7671, pp. 195–202, 2017, doi: 10.1038/nature23474.
- [6] M. Schuld and F. Petruccione, *Supervised Learning with Quantum Computers*, Cham, Switzerland: Springer, 2018.
- [7] E. Farhi and H. Neven, "Classification with quantum neural networks on near-term processors," arXiv:1802.06002, 2018. [Online]. Available: <https://arxiv.org/abs/1802.06002>
- [8] V. Havlíček et al., "Supervised learning with quantum-enhanced feature spaces," *Nature*, vol. 567, no. 7747, pp. 209–212, 2019, doi: 10.1038/s41586-019-0980-2.
- [9] A. Abbas, D. Sutter, C. Zoufal, A. Lucchi, A. Figalli, and S. Woerner, "The power of quantum neural networks," Oct. 2020, doi: 10.1038/s43588-021-00084-1.
- [10] M. Cerezo *et al.*, "Variational quantum algorithms," Sep. 01, 2021, *Springer Nature*. doi: 10.1038/s42254-021-00348-9.
- [11] J. R. McClean, S. Boixo, V. N. Smelyanskiy, R. Babbush, and H. Neven, "Barren plateaus in quantum neural network training landscapes," *Nat. Commun.*, vol. 9, no. 1, p. 4812, Dec. 2018, doi: 10.1038/s41467-018-07090-4.
- [12] M. Schuld, A. Bocharov, K. Svore, and N. Wiebe, "Circuit-centric quantum classifiers," Apr. 2018, doi: 10.1103/PhysRevA.101.032308.
- [13] A. Pérez-Salinas, A. Cervera-Lierta, E. Gil-Fuster, and J. I. Latorre, "Data re-uploading for a universal quantum classifier," *Quantum*, vol. 4, p. 226, Feb. 2020, doi: 10.22331/q-2020-02-06-226.
- [14] V. Lohweg, "Banknote authentication," UCI *Machine Learning* Repository, 2013. [Online]. Available: <https://archive.ics.uci.edu/ml/datasets/banknote+authentication>
- [15] P. Cortez, A. Cerdeira, F. Almeida, T. Matos, and J. Reis, "Wine quality," UCI *Machine Learning* Repository, 2009. [Online]. Available: <https://archive.ics.uci.edu/ml/datasets/Wine+Quality>
- [16] I. T. Jolliffe, *Principal Component Analysis*, 2nd ed., New York, NY, USA: Springer, 2002.