



Analisis Performa Variational Quantum Classifier (VQC) dengan ZZ Feature Map dan Angle Encoding Untuk Mengidentifikasi Serangan Jantung

Hilmia Rahma^{*}, Dahlan Abdullah, Desvina Yulisda

Sistem Informasi, Fakultas Teknik, Universitas Malikussaleh, Aceh Utara, Indonesia

Email: ^{1,*}hilmia.210180133@mhs.unimal.ac.id, ²dahlan@unimal.ac.id, ³desvina.yulisda@unimal.ac.id

Email Penulis Korespondensi: hilmia.210180133@mhs.unimal.ac.id

Abstrak—Serangan jantung merupakan salah satu penyebab kematian tertinggi di dunia dengan mortalitas yang meningkat akibat keterlambatan diagnosis dan keterbatasan fasilitas di beberapa wilayah. Deteksi dini dalam periode krusial satu jam pertama sejak gejala muncul (*golden hour*) sangat penting untuk menurunkan angka kematian dan meningkatkan prognosis pasien. Penelitian ini bertujuan untuk mengevaluasi kinerja *Quantum Neural Network* (QNN) dengan mengimplementasikan model *Variational Quantum Classifier* (VQC) menggunakan dua jenis *feature map*, yaitu *ZZ Feature Map* dan *Angle Encoding* untuk klasifikasi deteksi serangan jantung menggunakan dataset dari Kaggle. Proses penelitian meliputi pengumpulan dataset, *Exploratory Data Analysis* (EDA), *preprocessing* dan *splitting data*, pembuatan model menggunakan *ZZ Feature Map* dan *Angle Enoding*, diakhiri dengan evaluasi kinerja model. Hasil penelitian menunjukkan bahwa VQC dengan menggunakan *ZZ Feature Map* mencapai akurasi sebesar 52,27% dengan *confusion matrix* menunjukkan prediksi yang belum optimal dan nilai *precision*, *recall*, serta *F1-score* yang relatif rendah. Sementara VQC dengan menggunakan *Angle Encoding* mencapai akurasi sebesar 68,18% dengan *confusion matrix* yang menunjukkan jumlah prediksi benar lebih tinggi dan hasil *precision*, *recall*, serta *F1-score* yang lebih baik dibandingkan dengan VQC menggunakan *ZZ Feature Map*. Evaluasi menggunakan *confusion matrix* memperlihatkan bahwa model dengan *Angle Encoding* mampu meminimalkan kesalahan prediksi dan memberikan performa yang lebih stabil. Hasil ini mengindikasikan bahwa VQC dengan *Angle Encoding* lebih andal dan akurat dalam mendeteksi serangan jantung dibandingkan dengan VQC menggunakan *ZZ Feature Map*. Meskipun demikian, akurasi yang dicapai belum dapat dianggap optimal untuk implementasi klinis secara langsung. Temuan ini menegaskan perlunya pengembangan lebih lanjut guna meningkatkan performa model sekaligus menjadi langkah awal yang menjanjikan untuk menjadi landasan bagi pengembangan metode QNN yang lebih optimal di masa mendatang.

Kata Kunci: Serangan Jantung; Quantum Neural Network; Variational Quantum Classifier; Feature Map; Klasifikasi

Abstract—Heart attack is one of the leading causes of death worldwide, with mortality increasing due to delayed diagnosis and limited facilities in some regions. Early detection during the crucial first hour after symptoms appear (the golden hour) is crucial for reducing mortality and improving patient prognosis. This study aims to evaluate the performance of the Quantum Neural Network (QNN) by implementing the Variational Quantum Classifier (VQC) model using two types of feature maps: ZZ Feature Map and Angle Encoding, for heart attack detection classification using datasets from Kaggle. The research process includes dataset collection, Exploratory Data Analysis (EDA), data preprocessing and splitting, model building using ZZ Feature Map and Angle Encoding, ending with model performance evaluation. The results showed that VQC using ZZ Feature Map achieved an accuracy of 52.27% with a confusion matrix showing suboptimal predictions and relatively low precision, recall, and F1-score values. Meanwhile, VQC using Angle Encoding achieves an accuracy of 68.18% with a confusion matrix that shows a higher number of correct predictions and better precision, recall, and F1-score results compared to VQC using ZZ Feature Map. Evaluation using a confusion matrix shows that the model with Angle Encoding can minimize the prediction error. However, the accuracy achieved is not yet optimal for direct clinical implementation. These findings underscore the need for further development to enhance model performance, while serving as a promising first step toward establishing a foundation for developing more optimal QNN methods in the future.

Keywords: Heart Attack; Quantum Neural Network; Variational Quantum Classifier; Feature Map; Classification

1. PENDAHULUAN

Serangan jantung atau infark miokard merupakan kondisi ketika aliran darah ke otot jantung tersumbat secara tiba-tiba, biasanya disebabkan oleh penumpukan plak aterosklerotik atau gumpalan darah yang dapat menyebabkan kerusakan jaringan jika tidak segera ditangani [1], [2]. Berdasarkan laporan dari World Health Organization (WHO), penyakit jantung merupakan penyebab kematian nomor satu di dunia dengan lebih dari 17,9 juta kematian per tahun [3]. Di Indonesia, tren serupa terjadi dengan peningkatan kematian akibat serangan jantung yang dipicu oleh gaya hidup tidak sehat, stres, hipertensi, dan diabetes yang tidak terkontrol [4].

Deteksi dini dalam periode krusial satu jam pertama sejak gejala muncul (*golden hour*) sangat penting untuk menurunkan angka kematian dan meningkatkan prognosis pasien [5], [6]. Namun, metode deteksi konvensional seperti elektrokardiogram (EKG), pemeriksaan biomarker jantung (seperti CK-MB dan Troponin), serta evaluasi klinis menyeluruh memerlukan alat laboratorium serta tenaga medis ahli yang tidak selalu tersedia di daerah terpencil atau dalam kondisi darurat [7].

Seiring dengan perkembangan teknologi dan sistem informasi kesehatan, berbagai data biometrik seperti tekanan darah, denyut jantung, kadar gula darah, usia, serta biomarker jantung telah tersedia secara elektronik melalui sistem rekam medis. Ketersediaan data ini membuka peluang besar untuk pengembangan sistem pendukung keputusan berbasis data. Namun, pemanfaatan data tersebut untuk sistem prediksi otomatis masih belum digunakan secara optimal [8]. Pendekatan *machine learning*, khususnya pada *neural network* telah menunjukkan performa yang baik dalam klasifikasi data medis, prediksi risiko, dan diagnosis penyakit [9], [10], [11].

Beberapa penelitian sebelumnya telah menggunakan berbagai metode klasifikasi dalam upaya mendiagnosis



serangan jantung, salah satunya dengan menerapkan pendekatan *deep learning* berbasis *Convolutional Neural Network* (CNN) yang memanfaatkan data citra EKG melalui teknik transfer learning dan arsitektur khusus [12]. Selain itu, algoritma C4.5 juga telah digunakan untuk mengidentifikasi faktor risiko utama sebagai alat skrining awal untuk mengidentifikasi individu yang berisiko tinggi terkena serangan jantung [13]. Penelitian lainnya oleh [14] melakukan perbandingan beberapa model seperti *Naïve Bayes*, *Logistic Regression*, serta *Neural Network* untuk menunjukkan model dengan performa terbaik dalam memprediksi penyakit serangan jantung. Lebih lanjut, terdapat penelitian lain yang berupaya meningkatkan performa klasifikasi dengan mengoptimalkan model yang digunakan, salah satunya dengan menerapkan *Decision Tree* yang dipadukan dengan teknik *Synthetic Minority Over-sampling Technique* (SMOTE) untuk mengatasi permasalahan data yang tidak seimbang [15]. Penelitian dengan konsep serupa juga dilakukan oleh [16] yang mengusulkan kombinasi *K-Nearest Neighbor* (KNN) dan *Support Vector Machine* (SVM) yang dioptimalkan dengan *Principal Component Analysis* (PCA) untuk meningkatkan akurasi klasifikasi pada deteksi penyakit jantung.

Dalam beberapa tahun terakhir, telah muncul pendekatan komputasi baru yaitu *Quantum Neural Network* (QNN) yang memadukan keunggulan representasi dari *neural network* dengan kekuatan pemrosesan paralel dari komputasi kuantum [17], [18]. Salah satu implementasi QNN yang paling umum adalah *Variational Quantum Classifier* (VQC) yang menggunakan parameterisasi sirkuit kuantum untuk melakukan klasifikasi data [19]. Sejalan dengan perkembangan tersebut, penelitian ini menerapkan model VQC untuk mendeteksi serangan jantung dengan melakukan eksperimen pada variasi *feature map* sebagai upaya untuk mengoptimalkan performa model yang digunakan.


Dalam konteks klasifikasi kuantum, pemilihan *feature map* berperan penting dalam menentukan bagaimana data klasik diubah menjadi representasi kuantum [20]. *Feature map* merupakan proses yang mentransformasikan data input dari ruang aslinya ke ruang fitur berdimensi lebih tinggi agar pola yang tersembunyi menjadi lebih terlihat dan kelas-kelas data yang semula sulit dipisahkan menjadi lebih terpisah secara linear. Pemetaan yang tepat dapat meningkatkan kemampuan sirkuit dalam mengenali pola sehingga berpengaruh langsung pada akurasi dan kapasitas representasi model klasifikasi. Terdapat dua jenis model yang banyak digunakan, yaitu *ZZ Feature Map* yang menangkap korelasi antar fitur melalui *entanglement* dan *Angle Encoding* yang menjadikan nilai input ke rotasi sudut qubit. Pemilihan *feature map* yang tepat tidak hanya membantu pemisahan kelas yang lebih baik, tetapi juga memengaruhi kedalaman sirkuit, efisiensi komputasi, serta risiko *overfitting* atau *underfitting*.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menganalisis performa model *Variational Quantum Classifier* (VQC) dalam mengklasifikasikan serangan jantung berdasarkan data biometrik pasien dengan membandingkan penggunaan dua jenis *feature map* yaitu *ZZ Feature Map* dan *Angle Encoding*. Penelitian ini diharapkan dapat memberikan kontribusi awal terhadap penerapan model QNN dalam mendeteksi serangan jantung.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan model *Variational Quantum Classifier* (VQC) dengan *ZZ Feature Map* dan *Angle Encoding* untuk mendeteksi serangan jantung. Proses penelitian dilakukan melalui simulasi kuantum menggunakan perangkat lunak Qiskit versi 1.4.3 dan Qiskit Machine Learning versi 0.8.3 berbasis *cloud* untuk pembuatan *ZZ Feature Map*, *Angle Encoding*, *Quantum Circuit* atau *ansatz* pada model VQC. Selain itu, *NumPy* dan *Pandas* digunakan untuk manipulasi serta analisis data. Visualisasi data dilakukan dengan menggunakan pustaka *Matplotlib* dan *Seaborn*, sedangkan proses pengujian serta validasi model dilakukan dengan memanfaatkan modul *sklearn.preprocessing* dan *sklearn.model_selection* untuk pembagian data dan tahap *preprocessing*. Penelitian ini diawali dengan pengumpulan dataset dari sumber Kaggle, kemudian dilanjutkan dengan tahap *exploratory data analysis* (EDA) guna memahami karakteristik serta distribusi data [21]. Setelah itu, dilakukan *preprocessing* data serta pembagian dataset menjadi data latih dan data uji. Selanjutnya, dilakukan pembuatan *feature map* yang berfungsi untuk mengonversi dataset ke dalam bentuk *quantum state*. Seluruh tahapan tersebut dirancang untuk memastikan data yang digunakan telah siap sehingga dapat meningkatkan performa model yang akan digunakan.


Feature map yang digunakan terdiri dari dua jenis, yaitu *ZZ Feature Map* dan *Angle Encoding*, yang nantinya akan dibandingkan kinerjanya. Model VQC dibangun dengan menyesuaikan jumlah qubit pada *quantum circuit* dengan jumlah fitur pada dataset. Setelah itu, dirancang *quantum circuit* atau *ansatz* sebagai dasar model VQC untuk melakukan komputasi kuantum pada data yang telah dikonversi ke dalam bentuk *quantum state*. Data latih kemudian dimasukkan ke dalam model VQC agar model dapat mengenali dan mempelajari pola dari fitur dataset. Untuk mengoptimalkan proses pembelajaran, digunakan *optimizer* jenis COBYLA agar *objective function* atau *loss function* dapat diminimalkan secepat mungkin. Semakin kecil nilai *loss* yang diperoleh, semakin kecil pula tingkat kesalahan yang terjadi sehingga akhirnya dapat meningkatkan akurasi klasifikasi. Evaluasi kinerja dilakukan dengan menggunakan metrik yang relevan, seperti *loss*, akurasi pengujian dan *confusion matrix*. Analisis hasil dilakukan untuk mengevaluasi efektivitas masing-masing model dalam mendeteksi serangan jantung. Tahapan penelitian secara garis besar dapat dilihat dari diagram alir yang disajikan pada Gambar 1.



Gambar 1. Alur Penelitian

2.1 Pengumpulan Dataset

Penelitian menggunakan data sekunder yang diperoleh dari repository daring Kaggle, dengan sumber tautan: <https://www.kaggle.com/datasets/fatemehmohammadinia/heart-attack-dataset-tarik-a-rashid>. Dataset penelitian yang digunakan merupakan kumpulan data kejadian serangan jantung yang bertujuan untuk mengidentifikasi kondisi pasien yang mengalami atau tidak mengalami serangan jantung. Dataset tersebut terdiri atas 1.316 entri yang mencakup berbagai informasi klinis pasien, meliputi data demografik berupa usia dan jenis kelamin, hasil pemeriksaan fisik, dan parameter laboratorium yang relevan dengan diagnosis penyakit jantung. Ketiga jenis data tersebut diekstraksi menjadi delapan atribut yang selanjutnya dianalisis dan digunakan sebagai parameter penentu dalam proses klasifikasi. Distribusi data antara pasien yang mengalami serangan jantung dan tidak mengalami serangan jantung ditampilkan pada Gambar 2.




Gambar 2. Distribusi Dataset

2.2 Exploratory Data Analysis (EDA)

Untuk memahami karakteristik awal setiap fitur serta pola yang mungkin muncul dalam data, dilakukan *exploratory data analysis* (EDA). Visualisasi pairplot menggunakan pustaka *Seaborn* yang memperlihatkan distribusi masing-masing fitur serta hubungan antar fitur dalam penelitian ini disajikan pada Gambar 3. Hal ini bertujuan untuk mengidentifikasi kekuatan keterkaitan setiap fitur terhadap variabel target (*result*) sehingga dapat membantu menentukan fitur-fitur yang paling relevan. Dengan demikian, proses klasifikasi menjadi lebih efektif karena model dapat berfokus pada informasi yang benar-benar berkontribusi terhadap pembeda antar kelas.

Berdasarkan hasil visualisasi yang ditampilkan pada Gambar 3, diperoleh beberapa temuan penting terkait distribusi fitur-fitur yang diamati. Pertama, kadar troponin menunjukkan pemisahan yang sangat jelas antara pasien yang mengalami serangan jantung dan yang tidak sehingga menjadikan troponin sebagai biomarker paling kuat dalam membedakan kedua kelompok tersebut. Kemudian, kadar CK-MB menunjukkan pola serupa meskipun tidak sekuat troponin, namun tetap menunjukkan potensi sebagai indikator penting dalam mendukung diagnosis. Selanjutnya, kadar gula darah memperlihatkan perbedaan yang cukup mencolok dengan pasien yang mengalami serangan jantung cenderung memiliki gula darah lebih tinggi sehingga menandakan bahwa fitur tersebut relevan dalam mendeteksi risiko. Fitur usia menunjukkan bahwa pasien yang mengalami serangan jantung umumnya berada pada kelompok usia yang lebih tua. Meskipun tidak sekuat troponin dan CK-MB dalam memisahkan kelompok, usia tetap dapat dianggap sebagai faktor predisposisi. Selain itu, gender juga memperlihatkan kecenderungan menarik, yaitu laki-laki tampak lebih banyak mengalami serangan jantung dibandingkan perempuan sehingga mengindikasikan bahwa gender juga dapat dianggap sebagai predisposisi. Sementara itu, fitur seperti heart rate, tekanan darah sistolik, dan diastolik tidak menunjukkan perbedaan yang mencolok antara kedua kelompok pasien. Oleh karena itu, ketiga fitur ini dinilai kurang memberikan kontribusi signifikan dalam membedakan status serangan jantung secara visual.



Gambar 3. Grafik Seaborn Seluruh Fitur

Berdasarkan hasil eksplorasi visual menggunakan pairplot maka dapat disimpulkan bahwa beberapa fitur menunjukkan kekuatan distribusi yang cukup tinggi dalam membedakan pasien yang mengalami serangan jantung (positif) dan yang tidak mengalami serangan jantung (negatif). Di antara fitur-fitur yang dianalisis, Troponin, CK-MB, gula darah, dan usia merupakan fitur paling signifikan dan relevan dalam mengidentifikasi kecenderungan klinis terhadap kejadian serangan jantung. Dengan demikian, fitur-fitur tersebut layak dijadikan prioritas sebagai input utama dalam proses pemilihan fitur (*feature selection*) pada tahap pemodelan guna mengoptimalkan akurasi klasifikasi.

2.3 Preprocessing dan Splitting Data

Tahapan preprocessing dan splitting data dalam penelitian ini bertujuan untuk mempersiapkan dataset sebelum digunakan dalam pelatihan model untuk mengidentifikasi serangan jantung menggunakan model VQC dengan ZZ Feature Map dan VQC dengan Angle Coding. Proses *preprocessing* dilakukan dengan memfilter data sehingga hanya mencakup label dengan dua kategori utama, yaitu *positive* (mengalami serangan jantung) dan *negative* (tidak mengalami serangan jantung). Selanjutnya, kolom *Result* yang semula berupa nilai kategorikal dikonversi menjadi representasi numerik, yaitu 0 untuk kelas *negatif* dan 1 untuk kelas *positif*. Proses ini memudahkan model dalam mengenali pola karena label telah sesuai dengan representasi yang dapat diolah oleh algoritma VQC. Selain itu, fitur-fitur input diekstraksi dengan menghapus kolom target sehingga hanya menyisakan atribut-atribut klinis yang relevan, seperti kadar Troponin, CK-MB, kadar gula darah, dan usia.

Setelah melalui tahap *preprocessing*, dataset kemudian dibagi menjadi dua bagian menggunakan fungsi *train_test_split* dari pustaka *scikit-learn*, dengan rasio pembagian 80:20. Sebanyak 80% data digunakan sebagai *training set* untuk melatih model VQC, sedangkan 20% sisanya digunakan sebagai *testing set* untuk menguji kinerja model pada data yang belum pernah dilihat sebelumnya. Pembagian dilakukan secara acak dengan pengaturan random seed agar distribusi kelas tetap seimbang dan proses evaluasi dapat dilakukan secara objektif.

2.4 Pembuatan Model

Tahapan pembuatan model VQC dengan ZZ Feature Map dan Angle Encoding pada penelitian ini bertujuan untuk membangun dua arsitektur model klasifikasi berbasis quantum yang berbeda dalam cara memetakan data klasik ke dalam ruang fitur kuantum. Kedua model ini kemudian dibandingkan kinerjanya dalam mendeteksi serangan jantung.

a. VQC Menggunakan ZZ Feature Map

Proses pembuatan model VQC dengan ZZ Feature Map dilakukan dengan terlebih dahulu menyusun *quantum feature map* yang mampu menangkap korelasi antar fitur melalui operasi *entanglement*. Setiap fitur pada data input diproyeksikan ke rotasi qubit yang kemudian dihubungkan dengan gerbang kuantum (misalnya CNOT) untuk membentuk interaksi ZZ. Tahapan berikutnya adalah membangun *ansatz* atau *variational circuit* yang terdiri dari



beberapa lapisan rotasi parametrik (seperti RX, RY, atau RZ) dan lapisan entangling. Parameter-parameter ini dioptimasi menggunakan algoritma COBYLA untuk meminimalkan fungsi *loss* sehingga model dapat belajar memisahkan kelas serangan jantung (positif) dan tidak mengalami serangan jantung (negatif) secara optimal.

b. VQC Menggunakan *Angle Encoding*

Proses pemetaan data pada model VQC dengan *Angle Encoding* dilakukan dengan pendekatan yang lebih sederhana, yaitu mengubah setiap nilai fitur langsung menjadi sudut rotasi pada qubit (RX, RY, atau RZ) tanpa interaksi eksplisit antar fitur. Sama seperti pada metode sebelumnya, *variational circuit* dibentuk dengan lapisan-lapisan parametrik dan entangling, lalu dioptimasi menggunakan algoritma COBYLA untuk memperoleh representasi terbaik yang mampu memisahkan kelas data serangan jantung.

2.5 Evaluasi

Dalam penelitian ini, evaluasi terhadap model VQC dengan *ZZ Feature Map* dan model VQC dengan *Angle Encoding* dilakukan menggunakan beberapa metrik evaluasi, antara lain *classification report* dan *confusion matrix*. Pemilihan kedua metrik ini bertujuan untuk memperoleh gambaran yang komprehensif mengenai performa model dalam melakukan klasifikasi terhadap data serangan jantung. *Classification report* memberikan analisis kinerja model klasifikasi berdasarkan nilai yang diperoleh dari *confusion matrix* sehingga dapat memberikan gambaran rinci mengenai kemampuan model dalam mengklasifikasikan setiap kelas.

Confusion matrix sendiri merupakan salah satu metode evaluasi kinerja yang digunakan dalam permasalahan klasifikasi pada *machine learning*, baik untuk dua kelas maupun multikelas. Matriks ini menyajikan empat kombinasi utama antara hasil prediksi dan label sebenarnya, yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN) yang digunakan untuk menghitung nilai akurasi model [22]. Seperti terlihat pada gambar 4.

		Nilai Aktual	
		Positif	Negatif
Nilai Prediksi	Positif	TP	FP
	Negatif	FN	TN

Gambar 4. Confusion Matrix

Informasi dari keempat komponen tersebut menjadi dasar dalam perhitungan berbagai metrik evaluasi, seperti akurasi, presisi, *recall*, dan *F1-Score* [23]. Nilai-nilai tersebut dapat dihitung menggunakan persamaan (1), (2), (3), (4).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (2)$$


$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

$$F1 \text{ Score} = 2 \times \frac{Recall \times Precision}{Recall + Precision} \times 100\% \quad (4)$$

3. HASIL DAN PEMBAHASAN


3.1 Hasil

Berdasarkan penelitian yang dilakukan, model *Variational Quantum Classifier* (VQC) diuji menggunakan dua pendekatan *feature map* yang berbeda, yaitu *ZZ Feature Map* dan *Angle Encoding* untuk membandingkan efektivitas keduanya dalam mengidentifikasi serangan jantung. Tahapan pemodelan dilakukan setelah melalui *preprocessing* dan *splitting* data menjadi data latih dan data uji. Pada rancangan pertama, VQC dibangun menggunakan *ZZ Feature Map* yang memanfaatkan kombinasi gerbang *Hadamard* (H), *Phase* (P), dan *Controlled-NOT* (CNOT). Gerbang *Hadamard* berperan membentuk superposisi awal pada setiap qubit, sedangkan gerbang *Phase* (P) digunakan untuk menambahkan fase yang bergantung pada nilai fitur input sehingga data klasik dapat diproyeksikan ke dalam representasi kuantum. Interaksi antar qubit kemudian dimodelkan melalui gerbang *Controlled-NOT* (CNOT) yang membentuk operator ZZ sehingga memungkinkan terjadinya keterikatan (*entanglement*) di antara setiap qubit. Ketiga gerbang tersebut bekerja sama dalam membentuk hubungan non-linear fitur input dan mentransformasikan data klasik menjadi *quantum state* yang siap diproses oleh model VQC seperti ditunjukkan pada Gambar 5.




Gambar 5. Susunan *Quantum Gate* pada *ZZ Feature Map*

Setelah data diubah ke dalam representasi kuantum, proses komputasi dilanjutkan menggunakan *ansatz* berbasis *RealAmplitudes Circuit* untuk mengeksplorasi ruang parameter yang dapat dioptimalkan selama pelatihan. Model ini dibangun menggunakan empat qubit yang masing-masing mewakili fitur klinis relevan untuk identifikasi serangan jantung yang dipilih melalui tahap *exploratory data analysis* (EDA), yaitu Troponin, CK-MB, kadar gula darah, dan usia pasien. Optimisasi parameter dilakukan menggunakan algoritma COBYLA dengan jumlah iterasi sebanyak 60 sehingga diharapkan model dapat mencapai konfigurasi terbaik dalam meminimalkan nilai fungsi *loss* sebagaimana ditunjukkan pada Gambar 6.



Gambar 6. Susunan *Quantum Gate* pada *Quantum Circuit/ansatz* jenis *RealAmplitudes*

Selanjutnya, model VQC diuji menggunakan *Angle Encoding* untuk mengevaluasi perbedaan *feature map* dalam merepresentasikan data pada ruang kuantum. Berbeda dengan pendekatan sebelumnya, pada *Angle Encoding*, setiap nilai fitur secara langsung dikodekan menjadi sudut rotasi pada *Rotation Gate* sehingga memungkinkan representasi data klasik dalam bentuk kuantum dilakukan secara lebih sederhana dan linier. Rancangan sirkuit kuantum pada tahap ini dapat dilihat pada Gambar 7.




Gambar 7. Susunan *Quantum gate* untuk *feature map Angle Encoding*

Seperti pada model sebelumnya, proses komputasi dilakukan melalui *ansatz* berbasis *RealAmplitudes Circuit* dan *optimizer* COBYLA dengan jumlah iterasi yang serupa sehingga perbedaan performa yang diperoleh hanya disebabkan oleh karakteristik *feature map* yang digunakan. Model ini menggunakan empat qubit yang merepresentasikan fitur klinis Troponin, CK-MB, kadar gula darah, dan usia pasien dengan pemilihan jumlah qubit yang diselaraskan dengan hasil EDA serta konsisten dengan fitur yang digunakan pada implementasi sebelumnya.


Pada model VQC dengan menggunakan *ZZ Feature Map*, pelatihan nilai *loss* relatif tinggi dan mengalami fluktuasi cukup besar hingga sekitar iterasi ke-20. Hal ini menunjukkan bahwa pada tahap awal, model masih melakukan penyesuaian bobot untuk menemukan konfigurasi parameter yang lebih optimal. Terlihat pada gambar 9, seiring dengan

bertambahnya jumlah iterasi, pola *loss function* menunjukkan tren penurunan yang bertahap dan semakin stabil. Setelah melewati iterasi sekitar ke-40, nilai *loss* cenderung mendekati konvergensi dengan fluktuasi yang semakin kecil.



Gambar 9. Grafik Error VQC dengan *ZZ Feature Map* antara *Objective/Loss Function* terhadap Jumlah Iterasi

Sementara itu, Gambar 10 menunjukkan hubungan antara *loss function* dan jumlah iterasi selama pelatihan model VQC dengan *Angle Encoding*. Terlihat bahwa nilai *loss* mengalami fluktuasi yang cukup tajam pada awal pelatihan. Saat memasuki sekitar iterasi ke-30, nilai *loss* mulai menunjukkan tren penurunan yang lebih stabil. Selanjutnya hingga mendekati iterasi ke-60, nilai *loss* terus menurun secara bertahap dan mencapai kisaran yang lebih rendah dibandingkan fase awal. Meskipun pada beberapa titik masih terjadi sedikit fluktuasi, secara umum tren penurunan *loss* tetap terlihat hingga iterasi terakhir.



Gambar 10. Grafik Error VQC dengan *Angle Encoding* antara *Objective/Loss Function* terhadap Jumlah Iterasi

Hasil evaluasi pada model VQC dengan *ZZ Feature Map* menunjukkan bahwa akurasi pada data pelatihan (*training dataset*) mencapai 55%, sedangkan akurasi pada data pengujian (*test dataset*) sebesar 53%. Capaian akurasi yang masih berada di kisaran 50% menunjukkan bahwa kemampuan model dalam membedakan kelas positif dan negatif belum optimal, sebagaimana ditunjukkan pada Gambar 11.

training dataset:	0.55
test dataset	: 0.53

Gambar 11. Akurasi Training dan Test Dataset pada model VQC dengan *ZZ Feature Map*


Sementara pada model VQC dengan *Angle Encoding* menunjukkan akurasi yang lebih baik, yaitu mencapai 70% pada data pelatihan (*training dataset*), sedangkan akurasi pada data pengujian (*test dataset*) sebesar 68%. Hal tersebut menandakan bahwa model VQC dengan *Angle Encoding* memiliki kemampuan generalisasi yang lebih baik dibandingkan dengan model VQC yang menggunakan *ZZ Feature Map*, seperti ditunjukkan pada Gambar 12.

training dataset:	0.70
test dataset	: 0.68

Gambar 12. Akurasi Training dan Test Dataset pada model VQC dengan *Angle Encoding*


Gambar 13 menampilkan *confusion matrix* hasil klasifikasi model VQC dengan *ZZ Feature Map* terhadap data uji. Label 0 (negatif) merepresentasikan pasien yang tidak mengalami serangan jantung, sedangkan label 1 (positif) menunjukkan pasien yang mengalami serangan jantung. Dari matriks tersebut dapat diketahui bahwa sebanyak 53 pasien yang sebenarnya tidak mengalami serangan jantung berhasil diprediksi dengan benar oleh model *True Negative* (TN). Namun, terdapat 49 pasien yang seharusnya negatif justru diklasifikasikan sebagai mengalami serangan jantung *False Positive* (FP). Kemudian, model berhasil mengidentifikasi 85 pasien yang benar-benar mengalami serangan jantung

dengan tepat *True Positive* (TP), tetapi masih terdapat 77 pasien positif yang tidak berhasil dikenali dengan benar atau diprediksi sebagai negatif *False Negative* (FN). Hasil ini menunjukkan bahwa meskipun model mampu mengenali sebagian besar kasus positif, masih terdapat tingkat kesalahan klasifikasi yang cukup tinggi terutama pada kategori *false negative*.



Gambar 13. *Confusion Matrix* Model VQC dengan *ZZ Feature Map*

Sementara pada Gambar 14 menampilkan *confusion matrix* hasil klasifikasi model VQC dengan *Angle Encoding* terhadap data uji. Label 0 (negatif) merepresentasikan pasien yang tidak mengalami serangan jantung, sedangkan label 1 (positif) menunjukkan pasien yang mengalami serangan jantung. Dari matriks tersebut dapat diketahui bahwa sebanyak 51 pasien yang sebenarnya tidak mengalami serangan jantung berhasil diprediksi dengan benar oleh model *True Negative* (TN). Namun, terdapat 63 pasien yang seharusnya negatif justru diklasifikasikan sebagai mengalami serangan jantung *False Positive* (FP). Selanjutnya, model berhasil mengidentifikasi 129 pasien yang benar-benar mengalami serangan jantung dengan tepat *True Positive* (TP), sementara masih terdapat 21 pasien positif yang tidak berhasil dikenali dengan benar dan diprediksi sebagai negatif *False Negative* (FN).



Gambar 14. *Confusion Matrix* Model VQC dengan *Angle Encoding*

Secara keseluruhan, dibandingkan dengan model VQC dengan *ZZ Feature Map*, *confusion matrix* pada model VQC dengan *Angle Encoding* mampu mengenali lebih banyak pasien yang mengalami serangan jantung *True Positive* (TP) dan memiliki jumlah *False Negative* (FN) yang lebih sedikit sehingga menunjukkan performa klasifikasi yang lebih baik pada kasus positif. Begitu pula dengan hasil *classification report* terhadap kedua model disajikan pada Gambar 15.

Classification Report:				
	precision	recall	f1-score	support
0	0.41	0.52	0.46	102
1	0.63	0.52	0.57	162
accuracy			0.52	264
macro avg	0.52	0.52	0.52	264
weighted avg	0.55	0.52	0.53	264

VQC dengan *ZZ Feature Map*

Classification Report:				
	precision	recall	f1-score	support
0	0.71	0.45	0.55	114
1	0.67	0.86	0.75	150
accuracy			0.68	264
macro avg	0.69	0.65	0.65	264
weighted avg	0.69	0.68	0.67	264

VQC dengan *Angle Encoding*

Gambar 15. *Classification Report* pada Kedua Model

Pada *classification report* terlihat bahwa model VQC dengan *Angle Encoding* memperoleh nilai *precision* sebesar 0.67 untuk kelas positif (1) dan 0.71 untuk kelas negatif (0), sedangkan nilai *recall* untuk kelas positif mencapai 0.86, jauh lebih tinggi dibandingkan dengan model VQC dengan *ZZ Feature Map* yang hanya mencapai *recall* 0.52 pada kelas



positif. Nilai *f1-score* pada *Angle Encoding* juga lebih baik dengan 0.75 untuk kelas positif dibandingkan *f1-score* pada *ZZ Feature Map* sebesar 0.57 untuk kelas positif.

3.2 Pembahasan

Pada penelitian ini telah dibangun dan dilatih dua model klasifikasi dengan menggunakan pendekatan *Variational Quantum Classifier* (VQC), yaitu VQC dengan *ZZ Feature Map* dan VQC dengan *Angle Encoding* untuk mendeteksi kemungkinan terjadinya serangan jantung pada pasien berdasarkan sejumlah fitur klinis yang telah dipilih melalui tahap *Exploratory Data Analysis* (EDA). Kedua model tersebut dikembangkan dengan melakukan optimasi melalui pergantian *feature map* sehingga memungkinkan dilakukan perbandingan kinerja dan pemilihan konfigurasi yang paling baik dalam meningkatkan performa klasifikasi.

Eksperimen dilakukan menggunakan dataset *Heart Attack* yang diperoleh dari repository daring Kaggle. Dataset tersebut terdiri atas 1.316 entri, dengan rincian 808 entri pasien yang mengalami serangan jantung (positif) dan 508 entri pasien yang tidak mengalami serangan jantung (negatif). Seluruh dataset terlebih dahulu diproses melalui tahap *Exploratory Data Analysis* untuk memahami distribusi dan karakteristik fitur sehingga diperoleh fitur-fitur yang paling penting dan relevan terhadap variabel *result*. Dilanjutkan dengan tahap *preprocessing* untuk memisahkan fitur dan label serta mengubah label menjadi bentuk numerik. Kemudian, dataset dibagi menjadi dua bagian menggunakan metode *train_test_split*, yaitu *training set* sebanyak 80% untuk melatih model dan *testing set* sebanyak 20% untuk mengevaluasi kinerja model secara objektif.

Secara keseluruhan, nilai akurasi model VQC dengan *Angle Encoding* mencapai 68%, sedangkan model VQC dengan *ZZ Feature Map* hanya mencapai 52%. Meskipun masih terdapat kesalahan klasifikasi, performa keseluruhan model VQC dengan *Angle Encoding* menunjukkan tren yang menjanjikan sehingga konfigurasi ini dapat dipertimbangkan sebagai salah satu kandidat terbaik dalam eksperimen pemilihan *feature map*. Namun demikian, secara bersamaan hasil penelitian ini juga mengindikasikan bahwa penerapan *Quantum Neural Network* (QNN) dalam klasifikasi data medis masih menghadapi tantangan yang signifikan. Akurasi yang dicapai relatif rendah dan peningkatannya berjalan lambat yang menunjukkan bahwa proses pelatihan model QNN tidak selalu berjalan dengan optimal. Proses peningkatan akurasi pada model QNN menjadi sangat sulit dan memiliki tantangan tersendiri akibat fenomena yang bernama *Barren Plateaus*, yaitu kondisi ketika gradien menjadi sangat kecil sehingga proses pelatihan menjadi stagnan [24], [25]. Hal ini menegaskan bahwa fenomena tersebut turut berperan dalam menyebabkan model sulit mencapai konvergensi optimal meskipun telah dilakukan berbagai penyesuaian parameter [26], [27].

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, kinerja model VQC dengan *Angle Encoding* menunjukkan performa yang lebih unggul dibandingkan dengan model VQC menggunakan *ZZ Feature Map* dalam mendeteksi serangan jantung. Model VQC dengan *Angle Encoding* mampu mencapai akurasi sebesar 68,18%, sedangkan model VQC dengan *ZZ Feature Map* hanya mencapai akurasi 52,27%. Evaluasi menggunakan *classification report* juga memperlihatkan bahwa VQC dengan *Angle Encoding* menghasilkan nilai *precision*, *recall*, dan *F1-score* yang lebih tinggi, khususnya dalam mengklasifikasikan kelas positif atau pasien yang mengalami serangan jantung. Selain itu, *confusion matrix* menunjukkan bahwa model VQC dengan *Angle Encoding* memiliki jumlah prediksi benar yang lebih besar dan kesalahan klasifikasi yang lebih sedikit dibandingkan dengan VQC menggunakan *ZZ Feature Map*. Penelitian ini menyimpulkan bahwa penggunaan *Angle Encoding* sebagai *feature map* lebih sesuai untuk meningkatkan performa model VQC dalam mengidentifikasi serangan jantung dibandingkan dengan penggunaan *ZZ Feature Map*. Meskipun demikian, akurasi yang diperoleh belum dapat dianggap optimal untuk implementasi klinis secara langsung. Temuan tersebut menegaskan perlunya pengembangan lebih lanjut dari penelitian ini yang dapat dilakukan dengan memperluas dataset, mengeksplorasi desain *feature map* atau *ansatz* yang lebih efisien, serta memanfaatkan pendekatan *hybrid quantum-classical* guna meningkatkan akurasi dan meminimalkan risiko terjadinya fenomena *barren plateaus* sehingga performa model menjadi lebih stabil. Implementasi hasil penelitian ini diharapkan menjadi langkah awal yang menjanjikan sekaligus landasan bagi pengembangan metode QNN yang lebih optimal di masa mendatang.

REFERENCES

- [1] A. H. Association, "About heart attacks," 2023. [Online]. Available: <https://www.heart.org/en/health-topics/heart-attack/about-heart-attacks>
- [2] L. National Heart and Blood Institute, "Atherosclerosis," 2024. [Online]. Available: <https://www.nhlbi.nih.gov/health/atherosclerosis>
- [3] W. H. Organization, "The top 10 causes of death," 2023. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>
- [4] K. K. R. Indonesia, "Profil Kesehatan Indonesia 2023," Kementerian Kesehatan Republik Indonesia, 2024. [Online]. Available: <https://www.kemkes.go.id>
- [5] H.-J. Yoon, "Extending the Golden Hour: Recognizing the Critical Timing for MINOCA Treatment," *Korean Circ J*, vol. 54, no. 11, p. 707, 2024, doi: 10.4070/kcj.2024.0235.



- [6] S. V Rao *et al.*, “2025 ACC/AHA/ACEP/NAEMSP/SCAI Guideline for the Management of Patients With Acute Coronary Syndromes: A Report of the American College of Cardiology/American Heart Association Joint Committee on Clinical Practice Guidelines,” *Circulation*, vol. 151, no. 13, pp. e771–e862, Apr. 2025, doi: 10.1161/CIR.0000000000001309.
- [7] S. Højstrup, J. H. Thomsen, and E. Prescott, “Disparities in cardiovascular disease and treatment in the Nordic countries,” *The Lancet Regional Health - Europe*, vol. 33, p. 100699, Oct. 2023, doi: 10.1016/j.lanepe.2023.100699.
- [8] P. Mathur *et al.*, *Artificial Intelligence in Healthcare: 2021 Year in Review*. 2022. doi: 10.13140/RG.2.2.25350.24645/1.
- [9] P. Siswanto and R. Rulaningtyas, “Artificial Neural Network and Its Application in Medical Disease Prediction: Review Article,” in *Proceedings of the 4th Annual International Conference and Exhibition on Indonesian Medical Education and Research Institute*, SCITEPRESS - Science and Technology Publications, 2019, pp. 17–25. doi: 10.5220/0009387400170025.
- [10] R. S. Gupta, C. E. Wood, T. Engstrom, J. D. Pole, and S. Shrapnel, “A systematic review of quantum machine learning for digital health,” *NPJ Digit Med*, vol. 8, no. 1, p. 237, May 2025, doi: 10.1038/s41746-025-01597-z.
- [11] S. Badreddine, T. Alwadan, A. Omari, H. Al Ammari, R. Ashraf, and R. Moustaqim, “Neural network-based disease prediction: Leveraging symptoms for accurate diagnosis of multiple diseases,” *Edelweiss Applied Science and Technology*, vol. 9, no. 5, pp. 1932–1941, May 2025, doi: 10.55214/25768484.v9i5.7349.
- [12] Jithina Jose, Pavan Mishra, Jay Bansod, Twinkle Pingat, and Paramanand Malvadkar, “Heart Attack Prediction using CNN,” *International Journal of Advanced Research in Science, Communication and Technology*, pp. 142–152, May 2024, doi: 10.48175/IJARSC-18318.
- [13] A. Khalisatifa, H. Dela Arum, and M. I. Jambak, “Klasifikasi Risiko Penyakit Serangan Jantung Dengan Menggunakan Algoritma C4.5,” *Device*, vol. 14, no. 1, pp. 57–64, May 2024, doi: 10.32699/device.v14i1.6869.
- [14] R. Pranandito and H. Hendry, “Perbandingan Prediksi Penyakit Serangan Jantung Menggunakan Model Machine Learning,” *JIPi (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 8, no. 4, pp. 1228–1237, Nov. 2023, doi: 10.29100/jipi.v8i4.4165.
- [15] N. Yudistira and A. F. Putra, “Algoritma Decision Tree Dan Smote Untuk Klasifikasi Serangan Jantung Miokarditis Yang Imbalance,” *Jurnal Litbang Edusaintech*, vol. 2, no. 2, pp. 112–122, Dec. 2021, doi: 10.51402/jle.v2i2.48.
- [16] S. N. N. Arif, A. M. Siregar, S. Faisal, and A. R. Juwita, “Klasifikasi Penyakit Serangan Jantung Menggunakan Metode Machine Learning K-Nearest Neighbors (KNN) dan Support Vector Machine (SVM),” *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 8, no. 3, p. 1617, Jul. 2024, doi: 10.30865/mib.v8i3.7844.
- [17] R. S. Gupta, C. E. Wood, T. Engstrom, J. D. Pole, and S. Shrapnel, “A systematic review of quantum machine learning for digital health,” *NPJ Digit Med*, vol. 8, no. 1, p. 237, May 2025, doi: 10.1038/s41746-025-01597-z.
- [18] S. Wu, Y. Zhang, and J. Li, “Quantum data parallelism in quantum neural networks,” *Phys Rev Res*, vol. 7, no. 1, p. 013177, Feb. 2025, doi: 10.1103/PhysRevResearch.7.013177.
- [19] M. Schuld, A. Bocharov, K. M. Svore, and N. Wiebe, “Circuit-centric quantum classifiers,” *Phys Rev A (Coll Park)*, vol. 101, no. 3, p. 032308, Mar. 2020, doi: 10.1103/PhysRevA.101.032308.
- [20] M. Schuld, R. Sweke, and J. J. Meyer, “Effect of data encoding on the expressive power of variational quantum-machine-learning models,” *Phys Rev A (Coll Park)*, vol. 103, no. 3, p. 032430, Mar. 2021, doi: 10.1103/PhysRevA.103.032430.
- [21] S. Dhumad, “The Imperative of Exploratory Data Analysis in Machine Learning,” *Scholars Journal of Engineering and Technology*, vol. 13, no. 01, pp. 30–44, Jan. 2025, doi: 10.36347/sjet.2025.v13i01.005.
- [22] M. Grandini, E. Bagli, and G. Visani, “Metrics for multi-class classification: an overview,” *arXiv preprint arXiv:2008.05756*, 2020.
- [23] A. Tharwat, “Classification assessment methods,” *Applied Computing and Informatics*, vol. 17, no. 1, pp. 168–192, Jan. 2021, doi: 10.1016/j.aci.2018.08.003.
- [24] Z. Holmes, K. Sharma, M. Cerezo, and P. J. Coles, “Connecting Ansatz Expressibility to Gradient Magnitudes and Barren Plateaus,” *PRX Quantum*, vol. 3, no. 1, p. 010313, Jan. 2022, doi: 10.1103/PRXQuantum.3.010313.
- [25] M. Cerezo, A. Sone, T. Volkoff, L. Cincio, and P. J. Coles, “Cost function dependent barren plateaus in shallow parametrized quantum circuits,” *Nat Commun*, vol. 12, no. 1, p. 1791, Mar. 2021, doi: 10.1038/s41467-021-21728-w.
- [26] C. Ortiz Marrero, M. Kieferová, and N. Wiebe, “Entanglement-Induced Barren Plateaus,” *PRX Quantum*, vol. 2, no. 4, p. 040316, Oct. 2021, doi: 10.1103/PRXQuantum.2.040316.
- [27] A. Arrasmith, M. Cerezo, P. Czarnik, L. Cincio, and P. J. Coles, “Effect of barren plateaus on gradient-free optimization,” *Quantum*, vol. 5, p. 558, Oct. 2021, doi: 10.22331/q-2021-10-05-558.