

KOMPARASI SVM KLASIK DAN KUANTUM DALAM KLASIFIKASI BINER BIJI GANDUM (SEEDS)

COMPARISON OF CLASSICAL AND QUANTUM SVM IN BINARY CLASSIFICATION OF WHEAT SEEDS

Muhamad Akrom¹⁾

¹⁾Research Center for Quantum Computing and Materials Informatics, Fakultas Ilmu Komputer,
Universitas Dian Nuswantoro
Email : m.akrom@dsn.dinus.ac.id

Abstrak

Klasifikasi biner merupakan salah satu tugas penting dalam pembelajaran mesin, dengan aplikasi luas di berbagai bidang, termasuk pertanian dan pengolahan pangan. Penelitian ini membandingkan kinerja Support Vector Machine (SVM) klasik dan Quantum Support Vector Machine (QSVM) dalam klasifikasi biji gandum, dengan fokus pada akurasi, presisi, recall, F1-score, dan Area Under the Curve (AUC). Dataset biji gandum yang digunakan terdiri dari fitur-fitur fisik yang relevan untuk membedakan antara dua jenis biji. Hasil analisis menunjukkan bahwa QSVM secara signifikan mengungguli SVM klasik dalam semua metrik yang diukur, dengan akurasi lebih tinggi dan keseimbangan yang lebih baik antara presisi dan recall. Keunggulan QSVM dapat diatribusikan pada kemampuannya dalam menangani interaksi fitur yang kompleks dan mempercepat proses pelatihan melalui algoritma kuantum. Temuan ini menunjukkan potensi QSVM sebagai model yang lebih efektif untuk aplikasi klasifikasi biner, meskipun faktor-faktor seperti kompleksitas implementasi dan ketersediaan sumber daya komputasi kuantum perlu dipertimbangkan. Penelitian ini memberikan wawasan yang berharga untuk pengembangan metode klasifikasi yang lebih efisien dalam konteks pertanian dan bidang terkait lainnya.

Kata kunci: *Quantum Machine Learning, Quantum Support Vector Machine, Klasifikasi, Seeds.*

Abstract

Binary classification is one of the important tasks in machine learning, with wide applications in various fields, including agriculture and food processing. This study compares the performance of the classical Support Vector Machine (SVM) and Quantum Support Vector Machine (QSVM) in wheat grain classification, focusing on accuracy, precision, recall, F1-score, and Area Under the Curve (AUC). The wheat grain dataset consists of physical features relevant to distinguish between two types of grains. The analysis results show that QSVM significantly outperforms classical SVM in all measured metrics, with higher accuracy and a better balance between precision and recall. The superiority of QSVM can be attributed to its ability to handle complex feature interactions and accelerate the training process through quantum algorithms. These findings demonstrate the potential of QSVM as a more effective model for binary classification applications. However, factors such as implementation complexity and availability of quantum computing resources need to be considered. This study provides valuable insights for the development of more efficient classification methods in the context of agriculture and other related fields.

Keywords: *Quantum Machine Learning, Quantum Support Vector Machine, Classification, Seeds.*

1. PENDAHULUAN

Support Vector Machine (SVM) klasik telah lama digunakan sebagai algoritma andal untuk klasifikasi biner, termasuk dalam aplikasi bidang pertanian, seperti klasifikasi biji gandum. Namun, algoritma SVM klasik menghadapi keterbatasan ketika dihadapkan pada data berdimensi tinggi atau pola data kompleks [1], [2]. Tantangan ini semakin kritis dalam konteks analisis data yang membutuhkan efisiensi waktu komputasi dan keakuratan tinggi, terutama pada dataset dengan struktur yang tidak linier.

Quantum Support Vector Machine (QSVM), sebuah adaptasi kuantum dari SVM klasik, menawarkan pendekatan baru dengan memanfaatkan kemampuan unik dari komputasi kuantum. QSVM menggunakan superposisi dan *entanglement* qubit untuk melakukan pemrosesan data paralel, memungkinkan efisiensi yang lebih baik dalam penanganan data kompleks [3], [4], [5]. Superposisi adalah sifat unik qubit yang memungkinkan berada dalam kombinasi linear dari dua keadaan dasar, yaitu $|0\rangle$ dan $|1\rangle$, secara bersamaan. Ini memberi qubit kemampuan untuk

menyimpan dan memproses informasi lebih banyak dibandingkan bit klasik. Sementara itu, *entanglement* adalah fenomena dimana dua atau lebih qubit menjadi saling terkait sedemikian rupa sehingga keadaan satu qubit bergantung pada keadaan qubit lain, meskipun mereka terpisah secara fisik. Entanglement memungkinkan manipulasi data secara kolektif, yang penting dalam komputasi kuantum. Meskipun QSVM menunjukkan potensi dalam meningkatkan akurasi dan efisiensi, penelitian yang menguji keunggulan QSVM terhadap SVM klasik dalam klasifikasi dataset sederhana seperti biji gandum masih terbatas.

Sebagian besar penelitian QSVM berfokus pada dataset biologis atau aplikasi berbasis kesehatan dengan dimensi data yang tinggi. Studi yang mengaplikasikan QSVM pada dataset sederhana namun tetap relevan, seperti biji gandum, jarang dilakukan. Mayoritas studi QSVM fokus pada dataset kompleks dari bidang kesehatan atau biologis [6], [7], [8]. Penelitian terkait aplikasi QSVM pada dataset agrikultur seperti biji gandum masih sangat terbatas, sehingga analisis terhadap kelebihan dan kekurangan QSVM dalam konteks dataset ini menjadi kebutuhan mendesak [9]. Selain itu, penelitian komparatif yang menyeluruh antara QSVM dan SVM klasik untuk klasifikasi biner masih terbatas, terutama dalam konteks pengaruh karakteristik dataset terhadap performa kedua metode. Quantum Machine Learning (QML) merupakan bidang interdisipliner yang menggabungkan keunggulan komputasi kuantum dengan algoritma pembelajaran mesin (ML) [10]. QSVM, salah satu algoritma dalam QML, menunjukkan potensi untuk mempercepat komputasi, meningkatkan akurasi, dan efisiensi energi dibandingkan metode ML tradisional. Dalam konteks ini, biji gandum sebagai komoditas penting memberikan studi kasus yang menarik untuk menguji performa QSVM dibandingkan dengan SVM klasik.

SVM klasik sering menghadapi keterbatasan dalam menangani dataset kompleks atau berdimensi tinggi, sehingga memerlukan daya komputasi yang besar [11], [12]. QSVM menawarkan pendekatan alternatif yang menjanjikan efisiensi dalam penanganan dataset semacam itu. Namun, efektivitas QSVM pada dataset sederhana belum diteliti secara komprehensif [13], [14], [15]. Penelitian ini menawarkan kontribusi baru dengan mengaplikasikan QSVM pada klasifikasi biner dataset biji gandum, sebagai perwakilan dataset sederhana namun penting dalam bidang agrikultur; melakukan perbandingan sistematis antara QSVM dan SVM klasik berdasarkan metrik performa, seperti akurasi, efisiensi waktu komputasi, dan sensitivitas terhadap dimensi data; dan menyediakan analisis mendalam mengenai keunggulan dan keterbatasan QSVM pada dataset berbasis pertanian sederhana, yang menjadi dasar untuk studi lebih lanjut. Singkatnya, penelitian ini bertujuan untuk membandingkan performa QSVM dan SVM klasik dalam klasifikasi biner biji gandum; menganalisis efisiensi komputasi QSVM terhadap SVM klasik; dan memberikan wawasan baru tentang potensi QSVM untuk dataset agrikultur sederhana.

2. DASAR TEORI

2.1. Komputasi Kuantum

Dalam komputasi klasik, informasi disimpan dalam bit yang hanya memiliki nilai pasti, 0 atau 1. Sebaliknya, komputasi kuantum memanfaatkan qubit sebagai unit dasar informasi. Qubit memiliki keunikan karena dapat berada dalam keadaan superposisi, yaitu kombinasi linear dari dua basis komputasi, $|0\rangle$ dan $|1\rangle$. Secara matematis, keadaan superposisi ini direpresentasikan sebagai:

$$c_0|0\rangle + c_1|1\rangle \quad (1)$$

dimana c_0 dan c_1 adalah koefisien kompleks yang menggambarkan probabilitas relatif dari masing-masing basis [16]. Sifat ini memungkinkan qubit untuk menyimpan dan memproses berbagai kemungkinan solusi secara simultan, memberikan keunggulan dalam pengolahan data paralel dan tugas-tugas komputasi kompleks [17].

Superposisi memungkinkan komputer kuantum mengelola data berdimensi tinggi dan memecahkan masalah yang melibatkan eksplorasi ruang solusi besar dengan lebih cepat. Selain itu, entanglement atau keterbelitan antara qubit memberikan efisiensi tambahan dalam

pemrosesan informasi. Qubit yang terbelit saling terkait, sehingga perubahan pada satu qubit langsung memengaruhi qubit lainnya meskipun terpisah jarak jauh. Fenomena ini memungkinkan pemrosesan data yang terkoordinasi lebih efektif dibandingkan bit klasik [18], [19].

Kombinasi superposisi dan entanglement memberikan keunggulan eksponensial dalam performa komputasi kuantum, terutama dalam menangani masalah optimisasi, analisis data kompleks, dan tugas berbasis pembelajaran mesin. Dengan demikian, komputasi kuantum membuka peluang baru untuk menyelesaikan tantangan komputasi intensif yang sulit diatasi oleh sistem klasik..

2.2. QML

QML adalah integrasi algoritma kuantum dengan teknik pembelajaran mesin klasik untuk meningkatkan efisiensi dan kecepatan analisis data. Algoritma QML mencakup berbagai pendekatan seperti klasifikasi, clustering, regresi, dan optimisasi. Salah satu algoritma yang menonjol adalah QSVM, yang dirancang untuk memanfaatkan sifat kuantum dalam memisahkan kelas data dengan akurasi lebih tinggi dibandingkan metode klasik.

Pendekatan QML hybrid, yang menggabungkan komputasi klasik dan kuantum, telah terbukti efektif untuk menangani data kompleks berdimensi tinggi. Dalam aplikasi medis, misalnya, QSVM telah digunakan untuk menganalisis data kanker dan mengidentifikasi biomarker penting, menunjukkan potensi besar untuk pengembangan solusi berbasis QML di masa depan [20].

2.3. QSVM

QSVM adalah adaptasi kuantum dari SVM klasik, sebuah algoritma pembelajaran mesin yang diawasi (supervised learning). SVM memisahkan data ke dalam kelas berbeda dengan menentukan hyperplane optimal yang memaksimalkan margin antara dua kelas. Margin ini memastikan jarak terjauh dari titik data terdekat di setiap kelas, sehingga menghasilkan pemisahan yang optimal [21], [22].

Dalam SVM klasik, fungsi kernel digunakan untuk memetakan data non-linear ke ruang berdimensi lebih tinggi agar dapat dipisahkan secara linear. Kernel umum mencakup linear, polinomial, dan radial basis function (RBF) [23]. Pada QSVM, kernel kuantum menggantikan kernel klasik. Kernel ini memetakan data klasik ke ruang Hilbert kuantum melalui peta fitur kuantum, memungkinkan komputer kuantum untuk memproses data berdimensi tinggi dengan efisiensi yang lebih baik. Hasilnya, QSVM menunjukkan peningkatan akurasi dan kecepatan dalam tugas klasifikasi, terutama pada dataset dengan pola data yang sangat kompleks [24].

3. METODOLOGI PENELITIAN

Proses penelitian mencakup tahap pra-pemrosesan, pengolahan data, dan evaluasi model QML. Dalam penelitian ini, dataset seeds dari UCI Machine Learning Repository digunakan sebagai objek analisis (<https://archive.ics.uci.edu/dataset/236/seeds>). Dataset tersebut telah digunakan dalam berbagai penelitian untuk mengembangkan dan mengevaluasi metode statistik, pembelajaran mesin, dan teknik klasterisasi, seperti teknik regularisasi berbasis noise untuk meningkatkan stabilitas dan akurasi model dengan mengurangi overfitting, untuk mengilustrasikan metode mean shift denoising dalam inferensi statistik dalam menangkap pola data sambil mengurangi noise [25], untuk menguji algoritma klasterisasi aglomeratif berbasis diversifikasi yang berfokus pada perluasan hasil klasterisasi agar lebih mencerminkan variasi dalam data [26], untuk mengevaluasi transformasi fitur tanpa pengawasan berbasis informasi mutual yang bertujuan meningkatkan kinerja algoritma k-means dalam klasterisasi data heterogen [27], dan untuk menguji model klasifikasi Bayesian dalam menangani masalah klasifikasi multiclass [28].

Secara keseluruhan, dataset ini telah menjadi alat penting dalam pengembangan dan perbandingan algoritma di berbagai bidang penelitian. Dataset ini berisi 210 observasi dengan 7 fitur numerik (area permukaan, perimeter, kekompakan, panjang kernel, lebar kernel, koefisien asimetri, dan panjang kernel groove) sebagai atribut, serta satu label kategori yang

mengelompokkan data ke dalam tiga kelas: jenis gandum (Kama, Rosa, dan Canadian), dimana masing-masing kelas memiliki 70 data poin. Namun, karena tugas ini fokus pada klasifikasi biner, maka hanya digunakan kelas Kama dan Rosa, sementara kelas Canadian dihapus. Dalam konteks klasifikasi biner ini, kelas Kama dilabeli sebagai kelas positif dan kelas Rosa sebagai kelas negatif. Pemilihan kelas Kama dan Rosa untuk tugas klasifikasi biner didasarkan pada distribusi data yang seimbang (kelas Kama dan Rosa masing-masing memiliki 70 data poin, sehingga menyediakan distribusi yang seimbang untuk tugas klasifikasi biner. Hal ini penting untuk memastikan model tidak bias terhadap salah satu kelas dan dapat menghasilkan performa yang lebih akurat; juga didasarkan pada kompleksitas diferensiasi berdasarkan karakteristik dataset dimana kelas Kama dan Rosa memiliki atribut yang cukup berbeda untuk membangun pola klasifikasi, namun tetap menantang sehingga memerlukan model yang optimal.

Pemilihan ini bertujuan untuk mengevaluasi kemampuan model dalam membedakan kelas dengan fitur-fitur tertentu; selain itu berdasarkan pada tujuan penelitian dan generalisasi dimana fokus pada dua kelas ini memungkinkan peneliti untuk menyederhanakan masalah menjadi tugas biner, yang lebih mudah untuk dianalisis secara mendalam. Selain itu, hal ini memberikan kerangka awal untuk mengembangkan model yang nantinya dapat diperluas ke klasifikasi multiclass. Pemilihan ini tidak hanya didasarkan pada distribusi data yang seimbang tetapi juga pada relevansi dan kesesuaian tugas penelitian, sehingga hasil yang diperoleh dapat memberikan wawasan yang berarti untuk tugas klasifikasi secara umum.

Pada tahap pra-pemrosesan, label kategoris pada dataset dikonversi menjadi format numerik untuk memudahkan proses analisis algoritma ML. Label 'Kama' diberi nilai 0, dan label 'Rosa' diberi nilai 1. Konversi ini memastikan data berada dalam format yang sesuai untuk digunakan dalam algoritma QSVM.

Selanjutnya, dataset dinormalisasi menggunakan metode MinMaxScaler, yang menskalakan nilai fitur ke rentang [0, 1]. Normalisasi ini dilakukan untuk memastikan setiap fitur memiliki kontribusi yang seimbang selama pelatihan model [29], sehingga meningkatkan performa algoritma ML [29]. Setelah proses normalisasi, dataset dibagi secara acak menjadi data latih dan data uji dengan rasio 70:30. Karena dataset seeds relatif seimbang dalam distribusi kelas, tidak diperlukan penerapan teknik resampling [30].

Dalam penelitian ini, algoritma QML berbasis QSVM digunakan untuk tugas klasifikasi biner. Penggunaan paket Qiskit memfasilitasi pembangunan model dengan simulator sirkuit kuantum Qulacs. Algoritma ini memanfaatkan sirkuit kuantum, yang direpresentasikan melalui gerbang kuantum yang dibangun menggunakan kelas Parametric Quantum Circuit. Fungsi ansatz digunakan untuk merancang sirkuit kuantum, sedangkan fungsi circuit_drawer digunakan untuk memvisualisasikan struktur sirkuit [31].

Model dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan skor F1. Akurasi mengukur rasio prediksi yang benar terhadap jumlah keseluruhan prediksi. Presisi menentukan proporsi prediksi positif yang benar terhadap seluruh prediksi positif. Recall menilai proporsi positif yang berhasil diidentifikasi di antara semua kasus positif sebenarnya. F1-Score memberikan keseimbangan antara presisi dan recall melalui rata-rata harmonis keduanya. Selain itu, kinerja model dievaluasi menggunakan kurva ROC, yang memvisualisasikan performa model pada berbagai ambang batas klasifikasi [32], [33]. Persamaan evaluasi adalah sebagai berikut:

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \times 100 \tag{2}$$

$$Precision = \frac{TP}{(TP+FP)} \times 100 \tag{3}$$

$$Recall (Sensitivity) = \frac{TP}{(TP+FN)} \times 100 \tag{4}$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \tag{5}$$

Di sini, TP adalah singkatan dari true positives, TN untuk true negatives, FP untuk false positives, dan FN untuk false negatives. Metrik ini memberikan informasi penting tentang seberapa efektif model dapat mengklasifikasikan contoh dengan andal. Metrik ini dilakukan dengan mengevaluasi fungsionalitas model dan akurasi yang diantisipasi secara ekstensif di dalam kerangka klasifikasi berdasarkan *confusion matrix* pada Gambar 1.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 1. *Confusion matrix* untuk klasifikasi biner

Selain metrik akurasi, presisi, recall, dan skor F1, performa model juga dianalisis menggunakan Receiver Operating Characteristic-Area Under Curve (ROC-AUC). ROC menggambarkan hubungan antara True Positive Rate (TPR) atau sensitivitas dan False Positive Rate (FPR) pada berbagai ambang batas klasifikasi. TPR atau sensitivitas dan FPR dihitung sebagai:

$$TPR = \frac{TP}{(TP+FN)} \tag{5}$$

$$FPR = \frac{FP}{(FP+TN)} \tag{5}$$

Kurva ROC memplot TPR terhadap FPR, memberikan gambaran visual tentang kemampuan model dalam membedakan antara kelas positif dan negatif. Semakin dekat kurva ROC ke sudut kiri atas grafik, semakin baik performa model. Area Under Curve (AUC) mengukur total area di bawah kurva ROC dan menyediakan nilai numerik untuk mengevaluasi kinerja model. AUC berkisar antara 0 hingga 1, dengan nilai yang lebih tinggi menunjukkan kemampuan model yang lebih baik dalam membedakan kelas. Dalam penelitian ini, AUC digunakan untuk menilai kekuatan diskriminasi model QSVM. Nilai AUC yang mendekati 1 menunjukkan bahwa model dapat dengan baik memisahkan kelas gandum dalam dataset seeds. Evaluasi ROC-AUC ini memberikan wawasan tambahan tentang robustness model, terutama ketika kelas data memiliki distribusi yang seimbang seperti pada dataset ini. Kombinasi berbagai metrik, termasuk ROC-AUC, memungkinkan penilaian menyeluruh terhadap performa model QSVM. Hasil evaluasi ini menunjukkan keefektifan algoritma QSVM dalam mengklasifikasikan jenis gandum berdasarkan atribut numerik dalam dataset seeds, serta mendemonstrasikan potensi penerapan QML pada masalah klasifikasi berbasis data serupa.

4. PENGUJIAN DAN PEMBAHASAN

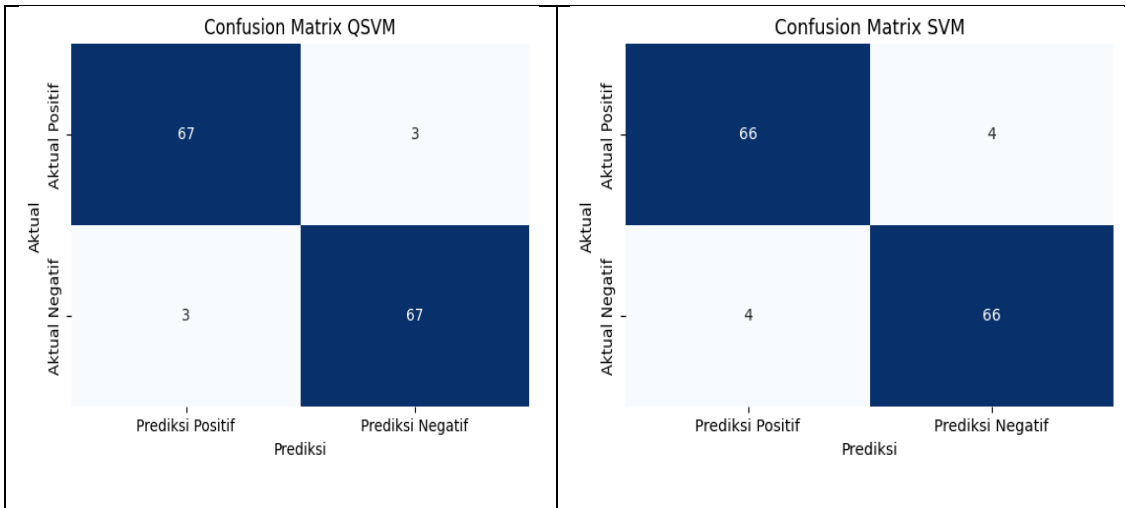
Berdasarkan Tabel 1, dapat diamati bahwa QSVM memiliki akurasi 95.6%, sedangkan SVM memiliki akurasi 94.7%. Ini menunjukkan bahwa QSVM sedikit lebih baik dalam mengklasifikasikan data dengan benar dibandingkan SVM. Akurasi yang tinggi menunjukkan bahwa model dapat secara efektif memprediksi kelas yang benar dari data, namun tidak memberikan informasi lengkap tentang kinerja model, terutama dalam kasus ketidakseimbangan kelas. Presisi QSVM adalah 95.1%, sementara presisi SVM adalah 94.3%. Presisi mengukur seberapa banyak dari prediksi positif yang benar-benar positif (dimana kelas Kama dilabeli sebagai kelas positif dan kelas Rosa sebagai kelas negatif). QSVM menunjukkan sedikit

keunggulan dalam hal ini, yang berarti bahwa ketika model memprediksi positif, ia lebih cenderung benar dibandingkan SVM. Recall QSVM (96.4%) lebih tinggi dibandingkan SVM (95%). Recall mengukur kemampuan model untuk menemukan semua contoh positif. QSVM lebih baik dalam mendeteksi kasus positif, yang dapat sangat penting dalam aplikasi di mana kehilangan positif (false negative) dapat memiliki konsekuensi serius, seperti dalam deteksi penyakit. F1-score QSVM adalah 95%, sedangkan SVM adalah 94.4%. F1-score adalah ukuran yang menggabungkan presisi dan recall, dan memberikan gambaran yang lebih baik tentang kinerja model ketika ada ketidakseimbangan kelas. QSVM menunjukkan kinerja yang lebih baik dalam hal ini, yang menunjukkan keseimbangan yang baik antara presisi dan recall. AUC untuk QSVM adalah 98%, sedangkan untuk SVM adalah 97%. AUC dari ROC memberikan gambaran yang baik tentang kemampuan model untuk membedakan antara kelas positif dan negatif. AUC yang lebih tinggi menunjukkan bahwa model memiliki kemampuan yang lebih baik untuk memisahkan kelas. QSVM menunjukkan kemampuan yang lebih baik dalam hal ini, yang berarti bahwa model ini lebih efektif dalam mengklasifikasikan data.

Tabel 1. Kinerja model

Model	Akurasi	Presisi	Recall	F1-score	ROC curve (AUC)
QSVM	0.956	0.951	0.964	0.950	0.98
SVM	0.947	0.943	0.950	0.944	0.97

Dari Gambar 2, QSVM memiliki satu TP lebih banyak dibandingkan SVM, yang menunjukkan bahwa QSVM sedikit lebih baik dalam mendeteksi kasus positif. QSVM memiliki 3 FN, sedangkan SVM memiliki 4 FN. Ini berarti QSVM lebih baik dalam mengidentifikasi semua contoh positif, yang penting dalam konteks di mana kehilangan positif dapat memiliki konsekuensi serius. QSVM juga memiliki lebih sedikit FP dibandingkan SVM. Ini menunjukkan bahwa QSVM lebih akurat ketika memprediksi kelas negatif, sehingga lebih sedikit kasus negatif yang salah diklasifikasikan sebagai positif. QSVM memiliki satu TN lebih banyak dibandingkan SVM, yang menunjukkan bahwa QSVM lebih baik dalam mengklasifikasikan contoh negatif dengan benar.



Gambar 2. Matrix Konfusi model

Secara keseluruhan, analisis kinerja yang lebih mendalam menggunakan confusion matrix menunjukkan bahwa QSVM tidak hanya memiliki akurasi yang lebih tinggi tetapi juga lebih baik dalam mengelola trade-off antara presisi dan recall. Dengan mengurangi jumlah false negatives dan false positives, QSVM memberikan keuntungan yang signifikan dalam aplikasi di mana akurasi klasifikasi sangat penting. Meskipun QSVM menunjukkan kinerja yang lebih baik dalam analisis ini, penting untuk mempertimbangkan konteks aplikasi dan kebutuhan spesifik saat

memilih model. Evaluasi lebih lanjut dengan dataset yang lebih besar dan beragam juga disarankan untuk memastikan bahwa kinerja model tetap konsisten di berbagai kondisi.

QSVM menunjukkan kinerja yang lebih baik dalam semua metrik yang dihitung dari confusion matrix. Ini mencakup akurasi, presisi, recall, dan F1-score, yang semuanya menunjukkan bahwa QSVM lebih efektif dalam mengklasifikasikan data dibandingkan SVM. Jumlah false negatives yang lebih rendah pada QSVM menunjukkan bahwa model ini lebih baik dalam mendeteksi kasus positif, yang sangat penting dalam banyak aplikasi, seperti diagnosis medis. Di sisi lain, jumlah false positives yang lebih rendah juga menunjukkan bahwa QSVM lebih akurat dalam mengklasifikasikan data negatif. Hal ini sangat penting dalam konteks di mana kesalahan dalam memprediksi positif dapat memiliki konsekuensi serius, seperti dalam diagnosis penyakit atau deteksi penipuan. Dengan mengurangi jumlah kasus negatif yang salah diklasifikasikan sebagai positif, QSVM membantu mengurangi biaya dan dampak yang terkait dengan tindakan yang mungkin diambil berdasarkan prediksi yang salah.

Secara keseluruhan, QSVM menunjukkan kinerja yang lebih baik dibandingkan SVM dalam semua metrik yang diukur. Ini menunjukkan bahwa QSVM mungkin lebih cocok untuk aplikasi yang memerlukan tingkat akurasi dan sensitivitas yang tinggi. Meskipun QSVM menunjukkan kinerja yang lebih baik, pemilihan model juga harus mempertimbangkan faktor lain seperti kompleksitas model, waktu pelatihan, dan interpretabilitas, yang masing-masing memiliki implikasi penting dalam aplikasi dunia nyata. QSVM umumnya memiliki kompleksitas yang lebih tinggi dibandingkan model klasik, terutama karena keterlibatan sirkuit kuantum dan pengolahan data dalam ruang fitur kuantum. Kompleksitas ini dapat meningkatkan kebutuhan sumber daya komputasi, seperti perangkat keras kuantum atau simulator kuantum, yang belum tersedia secara luas. Dalam aplikasi praktis, kompleksitas model juga dapat mempengaruhi skalabilitas saat dataset yang digunakan menjadi lebih besar. QSVM membutuhkan waktu pelatihan yang lebih lama dibandingkan dengan metode klasik seperti SVM atau model pembelajaran mesin lainnya. Hal ini disebabkan oleh proses simulasi kuantum, optimalisasi parameter kuantum, dan kebutuhan untuk mengeksekusi sirkuit kuantum berulang kali. Dalam lingkungan dengan batasan waktu atau data yang harus diproses dalam skala besar, waktu pelatihan yang lebih lama ini bisa menjadi kendala signifikan. Model klasik seperti SVM cenderung lebih mudah untuk diinterpretasikan karena prinsip dasarnya, misalnya, hyperplane pemisah pada SVM, jelas dan intuitif. Sebaliknya, QSVM, meskipun dapat memberikan hasil yang lebih baik, kurang intuitif karena melibatkan prinsip-prinsip kuantum seperti superposisi dan entanglement. Bagi pengguna non-teknis, keterbatasan dalam interpretabilitas ini dapat menyulitkan pemahaman dan penerapan hasil model untuk pengambilan keputusan. Oleh karena itu, meskipun QSVM menawarkan kinerja yang unggul, model ini lebih cocok digunakan pada skenario dengan kebutuhan akurasi tinggi yang dapat memanfaatkan keunggulan komputasi kuantum. Namun, untuk aplikasi yang memerlukan solusi cepat, mudah dipahami, dan hemat sumber daya, model klasik tetap menjadi pilihan yang relevan. Jika QSVM jauh lebih kompleks daripada SVM, mungkin ada trade-off antara kinerja dan efisiensi. Penting untuk mempertimbangkan konteks aplikasi saat memilih model. Misalnya, dalam aplikasi medis, recall yang tinggi mungkin lebih penting daripada presisi, sehingga QSVM mungkin lebih disukai. Di sisi lain, dalam aplikasi di mana false positives lebih berisiko, presisi mungkin lebih penting. Meskipun hasil ini menunjukkan bahwa QSVM lebih baik, penting untuk melakukan validasi silang dan pengujian lebih lanjut pada dataset yang berbeda untuk memastikan bahwa model ini tidak hanya cocok untuk dataset yang digunakan dalam pengujian ini.

5. KESIMPULAN

Quantum Support Vector Machine (QSVM) menunjukkan keunggulan yang signifikan dibandingkan Support Vector Machine (SVM) klasik dalam klasifikasi biner biji gandum (seeds). Dalam hal akurasi, QSVM mencatat hasil yang lebih tinggi dibandingkan SVM klasik. Selain itu, QSVM juga mengungguli SVM dalam metrik evaluasi lain, seperti presisi, recall, F1-score, dan AUC. Keunggulan ini terutama disebabkan oleh kemampuan QSVM untuk menangani interaksi antar fitur yang kompleks, yang sulit ditangkap sepenuhnya oleh SVM klasik, serta efisiensi pelatihan yang dihasilkan oleh penggunaan prinsip-prinsip komputasi kuantum. Namun,

meskipun QSVM menawarkan kinerja yang lebih baik, SVM klasik memiliki beberapa keunggulan praktis yang tidak dimiliki QSVM. Model SVM klasik lebih sederhana dalam implementasi, memerlukan sumber daya komputasi yang jauh lebih rendah, dan lebih mudah diinterpretasikan oleh pengguna. Hal ini menjadikan SVM klasik lebih cocok untuk aplikasi yang membutuhkan solusi cepat dengan keterbatasan perangkat keras atau pemahaman model. Sebaliknya, QSVM lebih ideal untuk tugas-tugas yang membutuhkan tingkat akurasi tinggi dan mampu memanfaatkan infrastruktur kuantum. Oleh karena itu, perbandingan ini menunjukkan bahwa pemilihan model harus disesuaikan dengan kebutuhan spesifik aplikasi, ketersediaan sumber daya, dan kompleksitas masalah. Untuk memastikan keunggulan QSVM secara konsisten, analisis lebih lanjut dan validasi pada dataset yang lebih besar dan beragam perlu dilakukan.

DAFTAR PUSTAKA

- [1] J. Preskill, "Quantum computing in the NISQ era and beyond," *Quantum*, vol. 2, Aug. 2018, doi: 10.22331/q-2018-08-06-79.
- [2] J. Bub, "QUANTUM INFORMATION AND COMPUTATION," *Philosophy of Physics*, pp. 555–660, Jan. 2007, doi: 10.1016/B978-044451560-5/50009-9.
- [3] N. S. H. Singh, and A. U. N., "An extensive review on quantum computers," *Advances in Engineering Software*, vol. 174, p. 103337, Dec. 2022, doi: 10.1016/J.ADVENGSOFT.2022.103337.
- [4] C. F. Tsai, Y. F. Hsu, C. Y. Lin, and W. Y. Lin, "Intrusion detection by machine learning: A review," *Expert Syst Appl*, vol. 36, no. 10, pp. 11994–12000, Dec. 2009, doi: 10.1016/J.ESWA.2009.05.029.
- [5] M. Akrom, S. Rustad, H. K. Dipojono, and R. Maezono, "A comprehensive approach utilizing quantum machine learning in the study of corrosion inhibition on quinoxaline compounds," *Artificial Intelligence Chemistry*, vol. 2, no. 2, p. 100073, Dec. 2024, doi: 10.1016/J.AICHEM.2024.100073.
- [6] A. P. Santosa and M. Akrom, "Quantum support vector regression for predicting corrosion inhibition of drugs," *Journal of Multiscale Materials Informatics*, vol. 1, no. 2, pp. 30–34, Aug. 2024, doi: 10.62411/jimat.v1i2.11427.
- [7] Y. Bai, X. Han, T. Chen, and H. Yu, "Quadratic kernel-free least squares support vector machine for target diseases classification," *J Comb Optim*, vol. 30, no. 4, pp. 850–870, Nov. 2015, doi: 10.1007/s10878-015-9848-z.
- [8] O. Farooq et al., "An enhanced approach for predicting air pollution using quantum support vector machine," *Sci Rep*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-69663-2.
- [9] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," May 01, 2021, Springer. doi: 10.1007/s42979-021-00592-x.
- [10] T. Kumar, D. Kumar, and G. Singh, "Brain Tumour Classification Using Quantum Support Vector Machine Learning Algorithm," *IETE J Res*, 2023, doi: 10.1080/03772063.2023.2245350.
- [11] D. Peral-García, J. Cruz-Benito, and F. J. García-Peñalvo, "Systematic literature review: Quantum machine learning and its applications," *Comput Sci Rev*, vol. 51, p. 100619, Feb. 2024, doi: 10.1016/J.COSREV.2024.100619.
- [12] L. Wei et al., "Quantum machine learning in medical image analysis: A survey," *Neurocomputing*, vol. 525, pp. 42–53, Mar. 2023, doi: 10.1016/J.NEUCOM.2023.01.049.
- [13] U. Ullah and B. Garcia-Zapirain, "Date of publication xxxx 00, 0000, date of current version xxxx 00, 0000. Quantum Machine Learning Revolution in Healthcare: A Systematic Review of Emerging Perspectives and Applications", doi: 10.1109/ACCESS.2017.DOI.

- [14] T. Suzuki and M. Katouda, "Predicting toxicity by quantum machine learning," *J Phys Commun*, vol. 4, no. 12, 2020, doi: 10.1088/2399-6528/abd3d8.
- [15] R. Zhang, J. Wang, N. Jiang, and Z. Wang, "Quantum support vector machine without iteration," *Inf Sci (N Y)*, vol. 635, pp. 25–41, Jul. 2023, doi: 10.1016/J.INS.2023.03.106.
- [16] V. Havlíček et al., "Supervised learning with quantum-enhanced feature spaces," *Nature*, vol. 567, no. 7747, pp. 209–212, Mar. 2019, doi: 10.1038/s41586-019-0980-2.
- [17] S. Park, D. K. Park, and J. K. K. Rhee, "Variational quantum approximate support vector machine with inference transfer," *Sci Rep*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-29495-y.
- [18] D. Willsch, M. Willsch, H. De Raedt, and K. Michielsen, "Support vector machines on the D-Wave quantum annealer," *Comput Phys Commun*, vol. 248, p. 107006, Mar. 2020, doi: 10.1016/J.CPC.2019.107006.
- [19] X. Vasques, H. Paik, and L. Cif, "Application of quantum machine learning using quantum kernel algorithms on multiclass neuron M-type classification," *Sci Rep*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-38558-z.
- [20] R. D. M. Simoes, P. Huber, N. Meier, N. Smailov, R. M. Fuchslin, and K. Stockinger, "Experimental Evaluation of Quantum Machine Learning Algorithms," *IEEE Access*, vol. 11, pp. 6197–6208, 2023, doi: 10.1109/ACCESS.2023.3236409.
- [21] A. Rana, P. Vaidya, and G. Gupta, "A comparative study of quantum support vector machine algorithm for handwritten recognition with support vector machine algorithm," *Mater Today Proc*, vol. 56, pp. 2025–2030, Jan. 2022, doi: 10.1016/J.MATPR.2021.11.350.
- [22] F. Novianti and N. Ulinuha, "SELEKSI FITUR ALGORITMA GENETIKA DALAM KLASIFIKASI DATA REKAM MEDIS PCOS MENGGUNAKAN SVM FEATURE SELECTION USING GENETIC ALGORITHM IN PCOS MEDICAL RECORD DATA CLASSIFICATION USING SVM," 2024.
- [23] K. A. Tychola, T. Kalampokas, and G. A. Papakostas, "Quantum Machine Learning—An Overview," Jun. 01, 2023, MDPI. doi: 10.3390/electronics12112379.
- [24] M. Akrom, S. Rustad, and H. K. Dipojono, "Variational quantum circuit-based quantum machine learning approach for predicting corrosion inhibition efficiency of pyridine-quinoline compounds," *Materials Today Quantum*, vol. 2, p. 100007, Jun. 2024, doi: 10.1016/j.mtquan.2024.100007.
- [25] J. Rothfuss et al., "Noise Regularization for Conditional Density Estimation," Jul. 2019, [Online]. Available: <http://arxiv.org/abs/1907.08982>
- [26] Y. Xiang and Y.-C. Chen, "Statistical Inference Using Mean Shift Denoising," Oct. 2016, [Online]. Available: <http://arxiv.org/abs/1610.03927>
- [27] N. Iam-On and T. Boongoen, "Diversity-driven generation of link-based cluster ensemble and application to data classification," *Expert Syst Appl*, vol. 42, no. 21, pp. 8259–8273, Nov. 2015, doi: 10.1016/J.ESWA.2015.06.051.
- [28] M. Wei, T. W. S. Chow, and R. H. M. Chan, "Clustering heterogeneous data with k-means by mutual information-based unsupervised feature transformation," *Entropy*, vol. 17, no. 3, pp. 1535–1548, 2015, doi: 10.3390/e17031535.
- [29] A. Sagingalieva, M. Kordzanganeh, N. Kenbayev, D. Kosichkina, T. Tomashuk, and A. Melnikov, "Hybrid Quantum Neural Network for Drug Response Prediction," *Cancers (Basel)*, vol. 15, no. 10, May 2023, doi: 10.3390/cancers15102705.
- [30] N. V Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," 2002.

- [31] M. Akrom, S. Rustad, and H. K. Dipojono, "Development of Quantum Machine Learning to Evaluate the Corrosion Inhibition Capability of Pyrimidine Compounds," *Mater Today Commun*, p. 108758, Mar. 2024, doi: 10.1016/J.MTCOMM.2024.108758.
- [32] S. Budi, M. Akrom, G. A. Trisnapradika, T. Sutojo, W. Aji, and E. Prabowo, "Optimization of Polynomial Functions on the NuSVR Algorithm Based on Machine Learning: Case Studies on Regression Datasets," *Scientific Journal of Informatics*, vol. 10, no. 2, 2023, doi: 10.15294/sji.v10i2.43929.
- [33] M. Akrom, "Investigation Of Natural Extracts As Green Corrosion Inhibitors In Steel Using Density Functional Theory," 2022.
- [34] M. Akrom, "Quantum Support Vector Machine for Classification Task: A Review," *Journal of Multiscale Materials Informatics*, vol. 1, no. 2, pp. 1–8, Jul. 2024, doi: 10.62411/jimat.v1i2.10965.