

# IMPLEMENTASI QSVM DALAM KLASIFIKASI BINER PADA KASUS KANKER PROSTAT

## IMPLEMENTATION OF QSVM IN BINARY CLASSIFICATION IN PROSTATE CANCER CASES

Nur Amalina Rahmaputri Hilmy<sup>1)</sup>, Muhamad Akrom<sup>2)</sup>

<sup>1), 2)</sup> Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro

<sup>2)</sup> Research Center for Quantum Computing and Materials Informatics, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro

Email : [111202113904@dinus.ac.id](mailto:111202113904@dinus.ac.id)<sup>1)</sup>, [m.akrom@dsn.dinus.ac.id](mailto:m.akrom@dsn.dinus.ac.id)<sup>2)</sup>

### Abstrak

Quantum Machine Learning (QML) telah menjadi area penelitian yang menjanjikan untuk meningkatkan kinerja komputasi, khususnya dalam menangani tugas klasifikasi yang kompleks dan berhubungan dengan data besar. Penelitian ini menerapkan algoritma Quantum Support Vector Machine (QSVM) untuk klasifikasi kanker prostat dan membandingkannya dengan model Support Vector Machine (SVM) klasik. Hasil eksperimen menunjukkan bahwa QSVM memiliki keunggulan dalam hal akurasi, dengan nilai 93%, lebih tinggi dibandingkan dengan SVM klasik yang mencatatkan akurasi 91%. Selain itu, QSVM juga menghasilkan nilai presisi, recall, dan F1-score yang lebih baik, yaitu 83%, 95%, dan 88%, sementara SVM klasik masing-masing memiliki presisi 82%, recall 93%, dan F1-score 87%. Hasil ini menunjukkan bahwa QSVM lebih efektif dalam menangani data berdimensi tinggi dan masalah klasifikasi yang kompleks, serta memiliki potensi yang besar dalam aplikasi medis, terutama untuk klasifikasi kanker dan penemuan biomarker. Temuan ini membuka peluang baru bagi penerapan QML dalam bidang kesehatan untuk meningkatkan akurasi dan efisiensi diagnostik.

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

### Abstract

Quantum Machine Learning (QML) is increasingly attracting attention as a potential solution to improve computational performance, especially in handling complex and big data-driven classification tasks. In this study, the Quantum Support Vector Machine (QSVM) algorithm is applied to prostate cancer classification, with the results compared to the classical Support Vector Machine (SVM) model. QSVM shows superiority in accuracy, reaching 0.93, compared to the classical SVM which has an accuracy of 0.91. In addition, QSVM produces precision, recall, and F1-score values of 0.83, 0.95, and 0.88, respectively, higher than the precision of 0.82, recall of 0.93, and F1-score of 0.87 of the classical SVM. These findings indicate that QSVM is more effective in handling high-dimensional data and complex classification, thus demonstrating the great potential of QML in medical applications, especially in cancer classification and biomarker discovery.

**Keywords:** Quantum Machine Learning, Quantum Support Vector Machine, Klasifikasi, Kanker Prostat.

## 1. PENDAHULUAN

Quantum Machine Learning (QML) adalah bidang yang berkembang pesat di persimpangan antara komputasi kuantum dan machine learning (ML). QML menarik perhatian luas dalam dunia riset dan industri karena potensinya untuk meningkatkan algoritma ML dengan kecepatan pemecahan masalah yang lebih tinggi, peningkatan akurasi, serta efisiensi energi yang lebih baik dibandingkan metode konvensional [1]. Salah satu keunggulan utama QML adalah penggunaan qubit, yang memungkinkan data diproses dalam kondisi superposisi, di mana satu qubit dapat berada dalam beberapa keadaan sekaligus. Ini menghasilkan kemampuan komputasi paralel yang jauh lebih besar dibandingkan *bit* klasik yang hanya memiliki dua keadaan (0 atau 1). Di samping itu, konsep *entanglement* dalam komputasi kuantum memperkuat interaksi antara qubit, menciptakan jaringan kompleks yang mampu memproses hubungan non-linear dengan efisien [2]. Kemampuan unik dari komputer kuantum ini membuatnya ideal untuk eksplorasi solusi yang lebih cepat dalam pemodelan hubungan kompleks, terutama dalam konteks ML dan optimasi pada *dataset* berukuran besar. Dalam aplikasi ML, QML mampu mengurangi waktu komputasi yang signifikan dengan menguji banyak kemungkinan solusi secara simultan, sehingga

mempercepat proses analisis dan pengambilan keputusan. Selain itu, sifat komputasi kuantum yang efisien dalam konsumsi energi menjadi keunggulan tambahan ketika diterapkan pada aplikasi ML yang membutuhkan daya komputasi tinggi [3]. Dengan potensi ini, QML membuka peluang baru dalam berbagai bidang, termasuk kesehatan, keuangan, dan logistik, di mana analisis data besar dan kompleks sangat penting untuk meningkatkan prediksi dan optimisasi dalam skala besar.

Di sisi lain, algoritma ML tradisional memainkan peran penting dalam membangun model yang mampu mempelajari dan mengidentifikasi pola dari data, dengan aplikasi luas di berbagai bidang, termasuk kesehatan. Dalam bidang ini, algoritma ML digunakan untuk mengklasifikasikan data biologis yang kompleks dan menemukan *biomarker* baru, yang dapat membantu dalam diagnosis dini dan pengembangan perawatan penyakit. Namun, ML tradisional sering menghadapi keterbatasan ketika dihadapkan dengan dataset besar atau pola data yang sangat kompleks, yang membutuhkan daya komputasi tinggi. Tantangan ini dapat membatasi skalabilitas dan efektivitas algoritma ML dalam analisis data yang lebih maju dan intensif, karena semakin besar dataset dan semakin rumit polanya, semakin intensif pula kebutuhan komputasinya. QML menawarkan pendekatan yang menjanjikan untuk mengatasi keterbatasan ini dengan memanfaatkan sifat-sifat unik dari komputasi kuantum. Dengan menggunakan superposisi dan entanglement, QML mampu mengelola data yang kompleks dan memproses informasi secara lebih efisien, memungkinkan pemodelan yang lebih canggih dan penanganan dataset besar dengan lebih cepat. Selain meningkatkan efisiensi komputasi, kemampuan ini membuka peluang untuk memperluas skalabilitas model, sehingga memungkinkan aplikasi ML dalam skenario yang sebelumnya tidak praktis menggunakan komputasi klasik. Dengan demikian, QML tidak hanya memperluas batas kemampuan pembelajaran mesin tetapi juga berpotensi mengubah cara memproses dan menganalisis data kompleks, khususnya dalam bidang yang membutuhkan pengelolaan data skala besar, seperti kesehatan, keuangan, dan penelitian ilmiah [4].

QML memiliki potensi yang signifikan untuk secara efektif mempengaruhi analisis data biologis dan medis dengan tujuan meminimalkan terjadinya kesalahan medis. Oleh karena itu, pemanfaatan kekuatan algoritma QML dapat meningkatkan analisis data medis untuk meningkatkan deteksi penyakit pada tahap awal. Pada akhirnya, hal ini akan meningkatkan manajemen pasien, mengurangi biaya, dan memberikan hasil pengobatan yang lebih baik. Dalam sebuah penelitian yang berfokus pada penggunaan QML untuk mengklasifikasikan jenis penyakit jantung tertentu, perbandingan antara klasifikasi kuantum dan algoritma klasik dilakukan menggunakan dataset kardiovaskular, dimana hasilnya menunjukkan akurasi algoritma QML mengalami peningkatan secara keseluruhan [5], [6]. Salah satu algoritma QML yang populer untuk tugas klasifikasi adalah *Quantum Support Vector Machine* (QSVM) yang dianggap sebagai versi kuantum dari algoritma *Support Vector Machine* (SVM) klasik. QSVM memiliki potensi untuk mempengaruhi metrik klasifikasi guna memberikan identifikasi dan diagnosis yang lebih baik [7].

QSVM, kernel kuantum berfungsi untuk melakukan operasi komputasi yang sulit atau tidak efisien jika dilakukan oleh metode klasik. Dengan memanfaatkan kernel kuantum, QSVM dapat mengeksplorasi kekuatan komputasi kuantum dalam pembelajaran mesin, khususnya dalam fungsi-fungsi kernel yang kompleks, yang pada gilirannya meningkatkan akurasi model dibandingkan dengan SVM klasik [8], [9]. Hal ini menjadi sangat relevan dalam analisis sistem biologis yang kompleks dan berdimensi tinggi, di mana QSVM memungkinkan pengujian lebih lanjut terhadap pengaruh rekayasa fitur terhadap akurasi klasifikasi. Karena kernel kuantum dapat menangani data berdimensi tinggi dengan lebih efisien, QSVM menjadi pilihan potensial dalam klasifikasi data biologis yang kompleks. Namun, keterbatasan komputasi kuantum saat ini menghambat eksplorasi penuh dari potensi QSVM, sehingga hasil yang diperoleh mungkin belum dapat digeneralisasi ke semua jenis dataset. Beberapa penelitian menunjukkan bahwa QSVM mampu mengungguli metode klasik dalam hal akurasi pada dataset tertentu, terutama yang memiliki pola data yang sangat kompleks. Meski begitu, dalam beberapa kasus, seperti pada dataset penyakit Diabetes, metode klasik menunjukkan akurasi keseluruhan yang sedikit lebih

tinggi dibandingkan algoritma kuantum [10], [11], [12]. Temuan ini menunjukkan bahwa efektivitas QSVM dapat bervariasi tergantung pada karakteristik dataset, dan meskipun QSVM menjanjikan keunggulan komputasi, penelitian lebih lanjut diperlukan untuk mengoptimalkan penerapannya dan memahami batasannya dalam berbagai domain aplikasi.

Penelitian ini, algoritma QSVM diterapkan pada dataset biologis berdimensi tinggi dari dunia nyata untuk klasifikasi jenis kanker prostat. Dalam perbandingan antara hasil yang diperoleh dari algoritma QML dan yang klasik, analisis klasifikasi secara keseluruhan menunjukkan bahwa model kuantum mencapai hasil yang lebih unggul. Mengingat keterbatasan komputer kuantum dalam jumlah qubit dan dimensi tinggi data sebagai ekspresi fitur, mengeksekusi algoritma QSVM pada simulator kuantum klasik.

## 2. DASAR TEORI

### 2.1. Komputasi Kuantum

Komputasi klasik, informasi disimpan dalam bit yang hanya memiliki dua nilai pasti, yaitu 0 atau 1. Sebaliknya, dalam komputasi kuantum, unit dasar informasi disebut quantum bit (*qubit*), yang memiliki sifat unik dibandingkan bit klasik. Secara matematis, *qubit* direpresentasikan sebagai vektor dalam ruang Hilbert kompleks berdimensi dua, dengan dua basis komputasi, yaitu  $|0\rangle$  dan  $|1\rangle$ . Tidak seperti bit klasik yang terbatas pada salah satu dari dua nilai tersebut, *qubit* dapat berada dalam keadaan superposisi, yaitu kombinasi linear dari kedua basis tersebut. Superposisi ini dinyatakan sebagai  $c_0|0\rangle + c_1|1\rangle$ , di mana  $c_0$  dan  $c_1$  adalah koefisien kompleks yang menentukan probabilitas keberadaan qubit dalam masing-masing keadaan dasar [13]. Keunikan ini memungkinkan *qubit* untuk memproses informasi dalam banyak keadaan sekaligus, memberikan potensi besar dalam komputasi paralel dan pengolahan data yang kompleks.

*Superposisi* adalah salah satu sifat fundamental dalam komputasi kuantum yang memungkinkan qubit berada dalam kombinasi kedua keadaan, 0 dan 1, secara bersamaan. Dengan adanya superposisi, qubit dapat mewakili banyak nilai sekaligus, sehingga memungkinkan komputer kuantum untuk memproses berbagai kemungkinan solusi dalam waktu yang sama. Kemampuan ini mempercepat pemecahan masalah yang kompleks, terutama dalam tugas-tugas yang memerlukan eksplorasi sejumlah besar kemungkinan, seperti optimisasi dan analisis data berdimensi tinggi [14]. Sifat ini menjadi salah satu alasan utama mengapa komputasi kuantum menawarkan keunggulan signifikan dibandingkan komputasi klasik dalam menghadapi tantangan komputasi intensif.

Selain superposisi, *entanglement* (keterbelitan) adalah fenomena penting dalam mekanika kuantum yang memberikan kekuatan unik pada komputasi kuantum. *Entanglement* terjadi ketika dua atau lebih qubit menjadi saling terkait sedemikian rupa sehingga keadaan satu *qubit* akan langsung memengaruhi keadaan *qubit* lain, terlepas dari jarak di antara mereka. Dalam keadaan terjerat, pengukuran pada satu qubit akan menyebabkan runtuhnya keadaan superposisi pada *qubit* yang terkait, memungkinkan transfer informasi secara instan dan efektif. Fenomena ini memungkinkan *qubit* yang terjerat untuk bekerja secara terpadu, sehingga dapat menyimpan dan memproses informasi lebih efisien daripada qubit individual. Kekuatan *entanglement* menjadikan komputer kuantum unggul dalam memecahkan masalah kompleks dengan skala komputasi yang tidak dapat dicapai oleh sistem klasik [15].

Karakteristik unik dari komputasi kuantum, seperti superposisi dan *entanglement*, memberikan potensi besar bagi komputer kuantum untuk mencapai kecepatan eksponensial dalam menyelesaikan masalah yang sulit dipecahkan oleh komputer klasik. Dalam konteks masalah yang melibatkan *dataset* besar atau ruang berdimensi tinggi, kemampuan *qubit* untuk berada dalam superposisi memungkinkan eksplorasi berbagai kemungkinan solusi secara simultan, sementara *entanglement* memperkuat hubungan antar *qubit*, meningkatkan efisiensi pemrosesan informasi. Keunggulan ini menghasilkan peningkatan signifikan dalam performa komputasi, sehingga memungkinkan solusi untuk masalah yang sebelumnya dianggap tidak praktis untuk dipecahkan menggunakan metode klasik. Dengan demikian, komputasi kuantum membuka jalan

baru untuk inovasi dalam berbagai bidang, termasuk pembelajaran mesin, optimisasi, dan analisis data kompleks.

## 2.2. Quantum Machine Learning (QML)

QML menggabungkan algoritma kuantum dengan metode ML klasik untuk meningkatkan kecepatan dan efisiensi dalam pemrosesan data. Algoritma QML mencakup klasifikasi kuantum, *clustering*, *regresi*, dan optimasi. Salah satu algoritma utama, QSVM, menggunakan prinsip kuantum untuk memisahkan kelas data dengan lebih akurat daripada metode klasik. Berbagai pendekatan QML, termasuk *hybrid* klasik-kuantum, menggabungkan kekuatan kuantum dan klasik untuk menangani data yang kompleks dan berdimensi tinggi. Pada penelitian ini, QSVM digunakan untuk mengklasifikasikan data kanker dan mengidentifikasi biomarker, menunjukkan potensi besar dalam aplikasi medis di masa depan [16].

## 2.3. SVM Kuantum

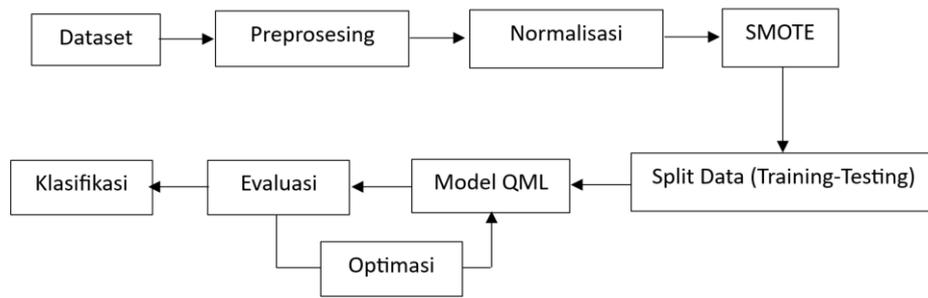
Algoritma QSVM memanfaatkan keunggulan komputasi kuantum untuk meningkatkan kinerja SVM klasik, yang merupakan algoritma ML yang diawasi (*supervised learning*) dan umum digunakan untuk masalah klasifikasi. QSVM bekerja dengan memisahkan titik data ke dalam kelas yang berbeda melalui identifikasi hyperplane optimal. Hyperplane ini ditentukan dengan memaksimalkan margin antara kelas-kelas tersebut, sehingga memastikan jarak terbesar dari titik data terdekat di setiap kelas [17], [18].

Algoritma SVM menggunakan fungsi kernel untuk mengklasifikasikan data yang tidak dapat dipisahkan secara linear. Fungsi kernel memetakan titik data ke dalam ruang berdimensi lebih tinggi, sehingga memungkinkan pemecahan masalah yang tidak dapat dipisahkan secara linear menggunakan peta fitur. Beberapa fungsi kernel yang umum digunakan dalam SVM adalah kernel linear, polinomial, dan radial basis function (RBF) [19].

QSVM, model kuantum diperkenalkan ke dalam metode kernel klasik, menciptakan kernel kuantum yang menjadi dasar QSVM. Pada QML, kernel kuantum diterapkan untuk memetakan data klasik ke dalam keadaan kuantum di ruang Hilbert, menggunakan peta fitur kuantum. Pemetaan ini memungkinkan komputer kuantum untuk menangani masalah klasifikasi yang kompleks dan berdimensi tinggi dengan efisiensi yang lebih baik dibandingkan pendekatan klasik, sehingga meningkatkan akurasi dan kecepatan dalam proses klasifikasi [20].

## 3. METODOLOGI PENELITIAN

Gambar 1 merupakan *flowchart* yang menggambarkan langkah-langkah dalam pra-pemrosesan, pengolahan data, serta evaluasi model QML. *Dataset* kanker Prostat dari Kaggle [21] adalah dataset yang digunakan dalam investigasi ini. *Dataset* ini adalah masalah kategorisasi dengan dua kelas: prostat kanker dan non-kanker. *Dataset* mencakup 100 observasi dengan 9 variabel, yang 8 di antaranya adalah variabel numerik (radius, tekstur, perimeter, area, kehalusan, kekompakan, simetri, dan dimensi fraktal) sebagai fitur, dan 1 adalah variabel kategoris (hasil diagnostik) sebagai label. Langkah pertama dalam pra-pemrosesan adalah mengonversi variabel kategoris 'hasil diagnostik' dari 'M' (ganas) dan 'B' (jinak) ke nilai numerik. Ini melibatkan penggantian 'M' dengan 1 untuk mewakili diagnosis kanker dan 'B' dengan 0 untuk mewakili diagnosis non-kanker. Menyiapkan dataset untuk algoritma ML yang memerlukan input numerik dengan mengonversi label kategoris ini ke dalam format numerik. Langkah pra-pemrosesan ini memastikan bahwa kumpulan data berada dalam format yang sesuai untuk analisis dan pemodelan lebih lanjut.



**Gambar 1.** Flowchart pemodelan

Untuk menyiapkan data untuk klasifikasi, membagi dataset secara acak menjadi set pelatihan dan set pengujian dalam rasio 70:30. Untuk mengatasi ketidakseimbangan antara kelas normal dan kanker dalam dataset pelatihan, menggunakan teknik *Synthetic Minority Over-Sampling Technique* (SMOTE). SMOTE menghasilkan titik data sintetis dalam ruang fitur dengan memanfaatkan algoritma *K-Nearest Neighbor* (KNN) [22]. Mengonversi label kategoris ke dalam format numerik. Langkah pra-pemrosesan ini memastikan bahwa kumpulan data berada dalam format yang sesuai untuk analisis dan pemodelan lebih lanjut.

Penelitian ini, paket QML Qiskit digunakan dalam tugas klasifikasi jenis kanker prostat. Algoritma QML ini berbasis pada Qiskit, salah satu simulator sirkuit kuantum tercepat yang dirancang untuk membantu para peneliti dalam operasi komputasi kuantum, dan telah menunjukkan percepatan signifikan dalam eksplorasi dan eksekusi algoritma dengan akurasi tinggi. Paket *Qiskit* memperkenalkan algoritma ML kuantum yang memanfaatkan simulator sirkuit kuantum *Qulacs*. Dalam algoritma QML ini, sirkuit kuantum dibuat menggunakan fungsi *Learning Circuit*. Sirkuit kuantum ini direpresentasikan sebagai rangkaian gerbang kuantum dan dikonstruksi menggunakan kelas *Parametric Quantum Circuit*. Fungsi *ansatz* digunakan untuk menghasilkan gerbang kuantum, dan hasil sirkuit tersebut dapat divisualisasikan menggunakan fungsi *circuit\_drawer* [23].

Akurasi, presisi, recall, dan skor F1 sangat penting saat mengevaluasi model pengklasifikasi. Akurasi didefinisikan sebagai rasio prakiraan yang tepat terhadap prediksi keseluruhan. Sementara akurasi menghitung proporsi prakiraan positif yang benar di antara semua prakiraan positif, recall menilai persentase prediksi positif yang benar di antara semua positif yang nyata. Skor F1 menyeimbangkan kedua metrik ini, rata-rata *harmonik recall* dan akurasi. Selain itu, dengan memplot rasio positif yang benar terhadap rasio positif yang salah, kurva ROC menunjukkan kinerja di seluruh ambang batas [24], [25].

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

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

$$Recall (Sensitivity) = \frac{TP}{(TP+FN)} \times 100 \tag{3}$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{(Precision+Recall)} \tag{4}$$

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 [26].

4. PENGUJIAN DAN PEMBAHASAN

Tabel 1 menunjukkan kinerja model QSVM menggunakan berbagai teknik penyandian dengan *ansatz Fidelity Quantum Kernel* pada akurasi model. QSVM 1, dengan penyandian *PauliFeatureMap*, mencapai akurasi tertinggi 0.93, sementara QSVM 2, menggunakan penyandian *ZFeatureMap*, mencapai 0.90. Hasilnya menyoroti bahwa teknik penyandian berdampak signifikan pada kinerja QSVM. Penyandian *PauliFeatureMap* menangkap fitur set data dengan lebih baik, yang menghasilkan kinerja yang lebih unggul jika dikombinasikan dengan *Fidelity Quantum Kernel*. Hal ini menggarisbawahi pentingnya memilih teknik penyandian yang tepat untuk meningkatkan kinerja model QML.

Tabel 1. Kinerja model QSVM

Model	Encoding	Ansatz	Akurasi
QSVM 1	<i>PauliFeatureMap</i>	<i>FidelityQuantumKernel</i>	0.93
QSVM 2	<i>ZFeatureMap</i>	<i>FidelityQuantumKernel</i>	0.90

Tabel 2. Kinerja model

Model	Akurasi (%)	Presisi (%)	Recall (%)	F1-score (%)
QSVM	93	83	95	88
SVM	91	82	93	87

Tabel 2 menunjukkan perbandingan antara QSVM dan SVM klasik berdasarkan beberapa metrik evaluasi, yaitu akurasi, presisi, *recall*, dan *F1-score*. Model QSVM menunjukkan akurasi 0.93, sedikit lebih tinggi dibandingkan dengan SVM yang memiliki akurasi 0.91. Ini menunjukkan bahwa QSVM mampu mengklasifikasikan sebagian besar sampel dengan benar dan unggul dalam hal ketepatan dibandingkan model SVM klasik. Perbedaan akurasi ini menunjukkan keunggulan komputasi kuantum dalam menangani dataset yang kompleks, memanfaatkan qubit dan superposisi untuk menghasilkan klasifikasi yang lebih akurat.

QSVM memiliki presisi 0.83, sedangkan SVM memiliki presisi 0.82, yang menunjukkan bahwa kedua model ini hampir setara dalam hal mengurangi kesalahan positif palsu. Namun, QSVM sedikit lebih unggul, yang berarti lebih baik dalam memastikan bahwa kelas yang terprediksi benar-benar berada dalam kategori yang sesuai, sehingga QSVM lebih efektif dalam tugas-tugas di mana meminimalkan positif palsu sangat penting, seperti dalam diagnosis penyakit.

Dari segi *recall*, QSVM memiliki nilai yang lebih tinggi yaitu 0.95 dibandingkan SVM yang memiliki *recall* 0.93. Hal ini menunjukkan bahwa QSVM lebih baik dalam menangkap semua sampel positif yang sebenarnya, atau dengan kata lain, lebih baik dalam mengidentifikasi kasus yang relevan (misalnya, mendeteksi semua kasus kanker). Dalam aplikasi medis, *recall* yang lebih tinggi sangat penting karena memastikan bahwa sebagian besar kasus yang benar tidak terlewatkan.

*F1-score*, yang merupakan harmonisasi antara presisi dan *recall*, menunjukkan bahwa QSVM memiliki nilai 0.88, sedikit lebih baik dibandingkan SVM dengan nilai 0.87. Hal ini menunjukkan bahwa QSVM memiliki keseimbangan yang lebih baik antara meminimalkan positif palsu (presisi) dan mendeteksi sebanyak mungkin positif sejati (*recall*), membuatnya lebih efisien dalam tugas klasifikasi yang memerlukan kompromi antara kedua metrik ini.

Secara keseluruhan, model QSVM menunjukkan performa yang sedikit lebih baik dibandingkan dengan SVM klasik dalam hal akurasi, presisi, *recall*, dan *F1-score*. Keunggulan QSVM ini mengindikasikan potensi kuat dari QML dalam meningkatkan hasil klasifikasi, terutama untuk dataset yang kompleks dan berdimensi tinggi, seperti data biologis atau medis. Meskipun perbedaannya tidak terlalu besar, peningkatan dalam *recall* dan *F1-score* oleh QSVM menunjukkan bahwa teknologi komputasi kuantum dapat memberikan keuntungan nyata dalam pengenalan pola dan klasifikasi data, terutama di bidang kesehatan, di mana keakuratan deteksi sangat penting. Hasilnya menunjukkan bahwa QSVM menghasilkan kinerja klasifikasi yang

kompetitif dengan algoritme ML SVM klasik. Hasil juga menggambarkan bahwa alur kerja terintegrasi kuantum memberikan keuntungan yang jelas atas algoritme klasik dalam hal akurasi ketika diterapkan pada kumpulan data yang identik.

## 5. KESIMPULAN

Penelitian ini difokuskan pada penerapan algoritma QML untuk klasifikasi data kanker prostat, dengan tujuan utama membandingkan kinerja komputasi kuantum dengan komputasi klasik pada masalah data berdimensi tinggi dan kompleksitas tinggi. Hasil analisis menunjukkan bahwa algoritma QML, khususnya QSVM, tidak hanya konsisten dengan hasil yang diperoleh dari model SVM klasik, tetapi juga menunjukkan keunggulan dalam pemrosesan data yang kompleks. Dalam hal ini, komputasi kuantum dapat mengatasi keterbatasan komputasi klasik karena memanfaatkan superposisi dan *entanglement*, yang memungkinkan pemrosesan paralel dalam skala besar dan meningkatkan efisiensi komputasi pada data biologis yang kompleks. Berbeda dengan komputasi klasik yang memproses data secara linier, metode kuantum dalam QSVM memperlihatkan peningkatan akurasi, presisi, recall, dan F1-score dibandingkan dengan SVM klasik, yang menegaskan potensinya dalam analisis medis yang menuntut daya komputasi tinggi. Temuan ini membuka peluang baru untuk implementasi QML dalam klasifikasi kanker dan penemuan *biomarker*. Namun, untuk sepenuhnya memanfaatkan potensi ini, penelitian lebih lanjut diperlukan untuk mengoptimalkan metode QML dan mengeksplorasi manfaatnya dalam skenario medis lain yang memiliki tantangan serupa.

## DAFTAR PUSTAKA

- [1] J. Preskill, Quantum computing in the NISQ era and beyond, *Quantum*. 2, 79 (2018), <https://doi.org/10.22331/q-2018-08-06-79>.
- [2] J. Preskill, Lecture notes for physics 229: quantum information and computation. *California Inst Technol*, 16(1), 1–8 (1998).
- [3] S. S. Gill, A. Kumar, H. Singh, M. Singh, K. Kaur, M. Usman, dan R. Buyya, “Quantum computing: a taxonomy, systematic review and future directions,” *Softw. Pract. Exp.*, vol. 52, no. 1, pp. 66–114, 2022.
- [4] M. I. Jordan dan T. M. Mitchell, “Machine learning: trends, perspectives, and prospects,” *Science*, vol. 349, no. 6245, pp. 255–260, 2015.
- [5] I. Sarker, “Machine learning: algorithms, real-world applications and research directions,” *SN Comput. Sci.*, vol. 2, no. 3, p. 160, 2021.
- [6] T. Wuest, D. Weimer, C. Irgens, dan K.-D. Thoben, “Machine learning in manufacturing: advantages, challenges, and applications,” *Prod. Manuf. Res.*, vol. 4, no. 1, pp. 23–45, 2016.
- [7] P. Mironowicz, A. Mandarino, A. Yilmaz, dan T. Ankenbrand, “Applications of quantum machine learning for quantitative finance,” *arXiv preprint arXiv:240510119*, 2024.
- [8] D. Maheshwari, B. Garcia-Zapirain, dan D. Sierra-Sosa, “Quantum machine learning applications in the biomedical domain: a systematic review,” *IEEE Access*, vol. 29, no. 10, pp. 80463–80484, 2022.
- [9] U. Ullah dan B. Garcia-Zapirain, “Quantum machine learning revolution in healthcare: a systematic review of emerging perspectives and applications,” *IEEE Access*, vol. 12, pp. 11423–11450, 2024.
- [10] D. Maheshwari, U. Ullah, P. A. O. Marulanda, A. G.-O. Jurado, I. D. Gonzalez, J. M. O. Merodio, dan B. Garcia-Zapirain, “Quantum machine learning applied to electronic healthcare records for ischemic heart disease classification,” *Hum.-Cent. Comput. Inf. Sci.*, vol. 13, no. 6, 2023.
- [11] P. Rebentrost, M. Mohseni, dan S. Lloyd, “Quantum support vector machine for big data classification,” *Phys. Rev. Lett.*, vol. 113, no. 13, p. 130503, 2014.

- [12] V. Havlíček, A. D. Córcoles, K. Temme, A. W. Harrow, A. Kandala, J. M. Chow, dan J. M. Gambetta, “Supervised learning with quantum-enhanced feature spaces,” *Nature*, vol. 567, no. 7747, pp. 209–212, 2019.
- [13] S. Park, D. K. Park, dan J. K. Rhee, “Variational quantum approximate support vector machine with inference transfer,” *Sci. Rep.*, vol. 13, no. 1, p. 3288, 2023.
- [14] D. Willsch, M. Willsch, H. De Raedt, dan K. Michielsen, “Support vector machines on the D-Wave quantum annealer,” *Comput. Phys. Commun.*, vol. 248, p. 107006, 2020.
- [15] X. Vasques, H. Paik, dan L. Cif, “Application of quantum machine learning using quantum kernel algorithms on multiclass neuron M-type classification,” *Sci. Rep.*, vol. 13, no. 1, p. 11541, 2023.
- [16] R. D. M. Simoes, P. Huber, N. Meier, N. Smailov, R. M. Fuchsli, dan K. Stockinger, “Experimental evaluation of quantum machine learning algorithms,” *IEEE Access*, vol. 11, pp. 6197–6208, 2023.
- [17] D. Maheshwari, D. Sierra-Sosa, dan B. Garcia-Zapirain, “Variational quantum classifier for binary classification: real vs synthetic dataset,” *IEEE Access*, vol. 10, pp. 3705–3715, 2021.
- [18] F. Novianti dan N. Ulinuha, “Seleksi fitur algoritma genetika dalam klasifikasi data rekam medis PCOS menggunakan SVM,” *Jurnal Ilmiah NERO*, vol. 9, no. 1, 2024.
- [19] K. A. Tychola, T. Kalampokas, dan G. A. Papakostas, “Quantum machine learning—an overview,” *Electronics*, vol. 12, no. 11, p. 2379, 2023.
- [20] M. Akrom, S. Rustad, T. Sutojo, H. K. Dipojono, R. Maezono, dan M. Solomon, “Quantum machine learning for corrosion resistance in stainless steel,” *Mater. Today Quantum*, vol. 3, p. 100013, 2024, <https://doi.org/10.1016/j.mtquan.2024.100013>.
- [21] A. Sagingalieva, M. Kordzanganeh, N. Kenbayev, D. Kosichkina, T. Tomashuk, dan A. Melnikov, “Hybrid Quantum Neural Network for Drug Response Prediction,” *Cancers (Basel)*, vol. 15, no. 10, May 2023. doi: 10.3390/cancers15102705.
- [22] N. V. Chawla, K. W. Bowyer, L. O. Hall, dan W. P. Kegelmeyer, “SMOTE: synthetic minority over-sampling technique,” *J. Artif. Intell. Res.*, vol. 16, pp. 321–357, 2002.
- [23] M. Akrom, S. Rustad, dan 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.
- [24] M. Akrom, S. Rustad, dan H. K. Dipojono, “Variational quantum circuit-based quantum machine learning approach for predicting corrosion inhibition efficiency of pyridine-quinoline compounds,” *Mater. Today Quantum*, vol. 2, p. 100007, Jun. 2024. doi: 10.1016/j.mtquan.2024.100007.
- [25] M. Akrom, S. Rustad, H. K. Dipojono, dan R. Maezono, “A comprehensive approach utilizing quantum machine learning in the study of corrosion inhibition on quinoxaline compounds,” *Artif. Intell. Chem.*, vol. 2, no. 2, p. 100073, 2024, <https://doi.org/10.1016/j.aichem.2024.100073>.
- [26] M. Akrom, “Quantum Support Vector Machine for Classification Task: A Review,” *J. Mult. Scale Mater. Infor.*, vol. 1, no. 2, pp. 1–8, 2024, <https://doi.org/10.62411/jimat.v1i2.10965>.