

IMPLEMENTASI MODEL QUANTUM INSPIRED SUPPORT VECTOR MACHINE UNTUK DETEKSI ANOMALI LALU LINTAS JARINGAN 5G BERBASIS MACHINE LEARNING

Tubagus Baits¹, Martanto², Denni Pratama³, Aris Pratama Putra⁴.

Program Studi Teknik Informatika¹
Program Studi Manajemen Informatika²³⁴

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
tubagusbaits710@gmail.com

(*) Corresponding Author : tubagusbaits710@gmail.com
Published : 30 Juni 2026

Abstract—This study proposes and implements a Quantum-Inspired Support Vector Machine (QSVM) model for anomaly detection in 5G network traffic. The main objective is to compare the performance of QSVM (implemented using QSVC with a ZZFeatureMap quantum kernel) against classical SVM (RBF-kernel SVC with class weighting) using a preprocessed and partially balanced 5G traffic dataset. The methodology includes feature preprocessing (scaling, encoding, and imbalance handling), quantum feature-map construction, hybrid quantum-classical model training on a simulator, and evaluation using precision, recall, F1-score, ROC-AUC, and inference time. Experimental results show that QSVC achieves relatively high overall accuracy (≈ 0.776) but fails to detect anomaly classes in the tested configuration (anomaly recall ≈ 0), indicating that high global accuracy can be misleading for highly imbalanced anomaly-detection tasks. In contrast, class-weighted classical SVC demonstrates better anomaly detection capability (precision ≈ 0.2625 ; recall ≈ 0.5250 ; F1 ≈ 0.35), although at the cost of increased false positives for normal traffic. These findings highlight the importance of minority-class-oriented metrics, more expressive quantum feature maps, and proper imbalance-handling strategies (oversampling or adjusted class weights). Future work is recommended to explore parameter sensitivity of the quantum feature map, validation on real NISQ hardware, and integration of interpretability techniques to enhance the operational usefulness of the detection system.

Keywords: Quantum-Inspired SVM; 5G Anomaly Detection; QSVC; Support Vector Machine; Quantum Kernel.

Abstrak—Penelitian ini mengusulkan dan mengimplementasikan model *Quantum-Inspired Support Vector Machine* (QSVM) untuk mendeteksi anomali pada lalu lintas jaringan 5G. Tujuan utama adalah membandingkan kinerja QSVM (menggunakan QSVC dengan ZZFeatureMap sebagai quantum kernel) dengan SVM klasik (SVC RBF, versi berbobot) pada dataset lalu lintas 5G yang telah dipraproses dan diseimbangkan sebagian. Metode meliputi pra-pemrosesan fitur (scaling, encoding, penanganan ketidakseimbangan), pembentukan quantum feature map, pelatihan model hibrida quantum-classical di simulator, serta evaluasi dengan metrik precision, recall, F1-score, ROC-AUC, dan waktu inferensi. Pada hasil eksperimen menunjukkan QSVC mampu mempertahankan akurasi global yang relatif tinggi (akurasi ≈ 0.776) namun gagal mendeteksi kelas anomali pada konfigurasi eksperimen tertentu (recall anomali ≈ 0), sehingga metrik akurasi global menyesatkan untuk tugas deteksi anomali yang tidak seimbang. Sebaliknya, SVC klasik berbobot menunjukkan kemampuan deteksi anomali yang lebih baik (precision ≈ 0.2625 ; recall ≈ 0.5250 ; F1 ≈ 0.35) meski mengorbankan peningkatan false positive pada kelas normal. Pada temuan ini menegaskan pentingnya fokus pada metrik kelas minoritas, desain feature map kuantum yang lebih sensitif terhadap anomali, serta strategi penanganan ketidakseimbangan (oversampling / penyesuaian bobot). Rekomendasi penelitian lanjutan mencakup pengujian sensitivity pada parameter feature map, serta validasi pada backend NISQ nyata, dan integrasi teknik interpretabilitas untuk meningkatkan kegunaan operasional sistem deteksi.

Kata Kunci: Quantum-Inspired SVM; Deteksi Anomali 5G; QSVC; Support Vector Machine; Quantum Kernel.

INTRODUCTION

Perkembangan jaringan seluler generasi kelima (5G) menghadirkan kemajuan signifikan dalam hal

konektivitas, kapasitas bandwidth, dan latensi rendah. Namun, kemajuan ini juga secara bersamaan memperluas lanskap ancaman keamanan siber. Berbagai penelitian terbaru menyoroti bahwa pergeseran menuju infrastruktur tervirtualisasi, *network slicing*, dan radio *access network* (RAN) berbasis perangkat lunak meningkatkan permukaan serangan di berbagai lapisan arsitektur 5G [1]. Kerentanan tersebut mencakup penurunan protokol lama (*legacy protocol downgrade*), kelemahan pada konfigurasi non-standalone (NSA), serta ancaman di lapisan fisik seperti jamming dan penyadapan. Penerapan transmisi data awal dan penyederhanaan protokol pada Release-16 juga menambah kompleksitas dalam menjamin keamanan jaringan. Oleh karena itu, para peneliti menyarankan penerapan strategi pertahanan berlapis, validasi ketat terhadap implementasi perangkat pengguna (UE) dan inti jaringan, serta pemanfaatan sistem deteksi anomali berbasis kecerdasan buatan (AI) dan pembelajaran mesin (ML) yang mampu menangani lalu lintas jaringan dalam volume besar secara real-time. [2].

Metode *machine learning* (ML) memiliki peran penting dalam meningkatkan kinerja deteksi anomali pada lingkungan 5G. Dengan kemampuan belajar dari pola data jaringan yang kompleks dan berdimensi tinggi, model ML dapat membedakan perilaku normal dan abnormal secara akurat. Kerangka kerja canggih seperti model hibrida yang menggabungkan *Support Vector Machine* (SVM) dengan *autoencoder* atau metode pembelajaran representasi mendalam telah menunjukkan peningkatan signifikan dalam presisi deteksi dan pengurangan kesalahan deteksi [3]. Selain itu, teknik rekayasa fitur serta pendekatan modern seperti arsitektur berbasis transformer dan *contrastive learning* mendukung pengenalan ancaman adaptif pada 5G yang dinamis. Meskipun demikian, penelitian masih menghadapi tantangan terkait keterjelasan model (*explainability*), skalabilitas, serta ketahanan terhadap serangan *adversarial*, khususnya dalam penerapan di dunia nyata [4].

Penelitian terbaru mengenai pembelajaran mesin terinspirasi kuantum (*Quantum-Inspired Machine Learning/QIML*) memperkenalkan paradigma baru untuk mengatasi keterbatasan model ML klasik dalam konteks keamanan siber. Algoritma yang terinspirasi kuantum, seperti yang memanfaatkan kernel kuantum, sirkuit variansional, dan pemetaan fitur berbasis superposisi, menunjukkan kapasitas ekspresif dan ketahanan yang lebih baik ketika diterapkan

pada data berdimensi tinggi dan kompleks [5]. Dalam tugas deteksi intrusi dan anomali, kerangka kerja hibrida antara algoritma kuantum dan klasik seperti *Quantum Support Vector Machine* (QSVM) telah menunjukkan hasil yang menjanjikan dengan peningkatan akurasi dan kemampuan generalisasi dalam kondisi bising maupun *adversarial*. Algoritma ini memanfaatkan prinsip-prinsip kuantum untuk memproyeksikan data klasik ke dalam ruang fitur yang lebih kaya, sehingga meningkatkan pemisahan antara pola lalu lintas normal dan berbahaya. [4].


Dalam konteks jaringan 5G, kerangka QSVM yang terinspirasi kuantum dapat memperkuat sistem deteksi anomali dengan pemodelan yang lebih baik terhadap perilaku lalu lintas yang nonlinier dan berdimensi tinggi di berbagai *network slice*. Mengingat kompleksitas lalu lintas 5G yang ditandai dengan virtualisasi, *slicing* dinamis, dan kebutuhan latensi ultra-rendah, metode ML tradisional sering kali kesulitan mempertahankan akurasi dan skalabilitas. Sebaliknya, pendekatan QIML menawarkan potensi untuk mencapai deteksi anomali berkecepatan tinggi dengan ketahanan dan adaptabilitas yang lebih baik. Secara keseluruhan, konvergensi antara riset keamanan 5G, deteksi anomali berbasis pembelajaran mesin, dan komputasi terinspirasi kuantum merepresentasikan arah transformasional dalam bidang keamanan siber modern. Integrasi ini tidak hanya menjawab tantangan dalam mendeteksi serangan canggih, tetapi juga membuka jalan bagi sistem pertahanan adaptif masa depan yang mampu berevolusi seiring perkembangan menuju era 6G [6]. Secara lebih luas, penerapan ML di sektor pertanian telah menunjukkan potensi besar dalam meningkatkan efisiensi, akurasi, dan keberlanjutan sistem produksi pangan. Dalam bidang genetik dan pemuliaan hewan, ML mampu mengekstraksi hubungan kompleks antara genotipe dan fenotipe, sekaligus membantu proses *feature selection* dan reduksi dimensi data. Integrasi ML dalam klasifikasi jamur dengan dukungan data visual, sensorik, dan atribut kimia juga dapat berkontribusi pada mitigasi risiko keracunan, pengelolaan hasil pertanian, serta konservasi ekosistem mikologi.

MATERIALS AND METHODS

Alur penelitian merupakan tahapan sistematis yang dirancang untuk memastikan proses penelitian berjalan secara terstruktur, terarah, dan sesuai dengan tujuan yang telah ditetapkan. Dalam penelitian ini, alur penelitian disusun untuk menggambarkan langkah-langkah yang dilakukan dalam mengembangkan dan mengevaluasi model Quantum-Inspired Support Vector Machine (QSVM)

untuk deteksi anomali pada jaringan 5G. Setiap tahapan dirancang secara berurutan mulai dari identifikasi permasalahan hingga penarikan kesimpulan, sehingga hasil penelitian dapat diperoleh secara valid dan dapat dipertanggungjawabkan secara ilmiah.

Alur penelitian ini mencakup beberapa proses utama, yaitu pengumpulan data, pra-pemrosesan, rekayasa fitur, pemodelan, hingga evaluasi kinerja model. Pendekatan ini tidak hanya menitikberatkan pada pembangunan model, tetapi juga pada kualitas data dan metode analisis yang digunakan. Dengan adanya alur penelitian yang jelas, diharapkan penelitian ini mampu memberikan gambaran menyeluruh mengenai proses pengembangan sistem deteksi anomali berbasis QSVM serta memudahkan dalam proses replikasi penelitian di masa mendatang.



Gambar 1. Alur Penelitian

Penelitian ini diawali dengan tahap identifikasi masalah yang berfokus pada keterbatasan metode Support Vector Machine (SVM) klasik dalam mendeteksi anomali pada jaringan 5G yang memiliki karakteristik lalu lintas yang kompleks, heterogen, dan berdimensi tinggi. Selanjutnya dilakukan studi literatur untuk mengkaji berbagai teori dan penelitian terdahulu terkait machine learning, deteksi anomali jaringan, serta pendekatan Quantum-Inspired Machine Learning khususnya Quantum Support Vector Machine (QSVM). Tahap ini bertujuan untuk menemukan kesenjangan penelitian serta merumuskan pendekatan yang tepat dalam pengembangan model.

Tahap berikutnya adalah pengumpulan data yang menggunakan dataset benchmark seperti CIC-IDS2017, NSL-KDD, UNSW-NB15, dan 5G-NIDD, serta dapat didukung dengan data sintesis untuk mengatasi ketidakseimbangan kelas. Data yang diperoleh kemudian melalui proses preprocessing yang meliputi pembersihan data, penanganan missing value, encoding fitur kategorikal, normalisasi, serta penyeimbangan data menggunakan teknik seperti SMOTE atau penyesuaian bobot kelas. Setelah itu dilakukan feature engineering yang mencakup seleksi dan ekstraksi fitur, serta transformasi fitur ke dalam representasi yang sesuai untuk model, termasuk pemetaan ke quantum feature map pada QSVM.

Selanjutnya, data dibagi menjadi data latih dan data uji dengan proporsi tertentu, kemudian dilakukan tahap pemodelan dengan membangun dua pendekatan yaitu model SVM klasik sebagai baseline dan model QSVM sebagai pendekatan utama. Kedua model dilatih menggunakan data latih dengan proses tuning hyperparameter untuk memperoleh performa optimal. Setelah pelatihan, model dievaluasi menggunakan berbagai metrik seperti akurasi, precision, recall, F1-score, ROC-AUC, serta confusion matrix untuk menilai kemampuan deteksi anomali secara komprehensif. Tahap akhir meliputi analisis hasil untuk membandingkan performa kedua model, diikuti dengan penarikan kesimpulan dan pemberian saran sebagai rekomendasi untuk penelitian selanjutnya.

RESULTS AND DISCUSSION

Validasi berbasis rolling-window dilakukan untuk mengamati perubahan performa model pada data berurutan secara temporal. Evaluasi dilakukan pada tiap window untuk mencatat perubahan akurasi, presisi, recall, dan stabilitas model.

Hasil validasi menunjukkan bahwa performa recall terhadap kelas anomali mengalami fluktuasi signifikan pada beberapa window, yang mengindikasikan adanya perubahan distribusi data. Pola ini selaras dengan gejala concept drift, meskipun belum divisualisasikan dalam bentuk grafik. QSVC menunjukkan kestabilan akurasi global namun sensitivitas rendah terhadap kelas minoritas, sedangkan weighted SVC lebih responsif terhadap anomali tetapi menunjukkan penurunan performa yang lebih cepat ketika distribusi data berubah.

```

### Tabel Metrik Komparatif LENGKAP (Fokus Anomali) ###

```

	Model	Akurasi_Latih	Akurasi	Presisi_Anomali	Recall_Anomali	F1-Score_Anomali
0	QSVC (Quantum Kernel)	0.7762	0.7778	0.0000	0.0000	0.0000
1	SVC Klasik (Weighted)	NaN	0.5667	0.2625	0.5250	0.3500


```

### Analisis Kinerja Kuantitatif (Fokus F1-Score Anomali) ###
* Perbedaan F1-Score Anomali (QSVC - SVC Klasik Weighted): **~0.3500**
-> Model SVC Klasik (Weighted) Unggul Signifikan dalam mendeteksi Anomali.

```

Gambar 2 Metrik komparatif

Gambar 2 Hasil komparatif antara model QSVC (Quantum Kernel) dan SVC Klasik (Weighted) menunjukkan perbedaan kinerja yang cukup signifikan dalam mendeteksi anomali. Model QSVC memiliki akurasi latih sebesar 0.7762 dan akurasi pengujian 0.7778, namun tidak mampu mendeteksi anomali sama sekali, yang terlihat dari nilai presisi, recall, dan F1-Score anomali yang semuanya 0.0000. Hal ini mengindikasikan bahwa meskipun QSVC tampak stabil pada data umum, model tersebut gagal mengidentifikasi kelas minoritas atau anomali. Sebaliknya, SVC Klasik (Weighted) menunjukkan performa yang lebih baik dengan nilai presisi anomali 0.2625, recall 0.5250, dan F1-Score 0.3500, meskipun akurasi keseluruhannya tidak setinggi QSVC. Perbedaan F1-Score anomali sebesar -0.3500 (QSVC - SVC Klasik Weighted) memperkuat kesimpulan bahwa model SVC Klasik (Weighted) secara signifikan lebih unggul dalam mendeteksi anomali. Temuan ini menegaskan bahwa penanganan bobot kelas sangat berpengaruh dalam skenario data tidak seimbang, terutama ketika fokus utama analisis adalah kemampuan model dalam mengenali kejadian langka atau anomali.



Gambar 3 Count confusion matrik

Gambar 3 menyajikan analisis kuantitatif performa model dalam mendeteksi anomali dengan fokus pada metrik F1-Score serta interpretasi confusion matrix. Perbedaan F1-Score menunjukkan bahwa model SVC Klasik (Weighted) secara signifikan lebih unggul dibandingkan QSVC, dengan selisih sebesar -0.3500 yang berarti QSVC jauh lebih lemah dalam mengidentifikasi kasus anomali. Hasil ini diperkuat oleh interpretasi confusion matrix yang memperlihatkan kemampuan SVC Klasik (Weighted) mendeteksi 21 anomali (True Positive), sedangkan QSVC tidak mendeteksi satu pun anomali.

Selain itu, nilai True Negative yang tinggi pada kedua model menunjukkan bahwa keduanya cukup baik dalam mengenali data normal, namun hanya SVC Klasik (Weighted)


yang mampu menjaga keseimbangan antara deteksi normal dan anomali secara lebih efektif. Walaupun SVC Klasik menghasilkan 59 False Positive, kondisi ini relatif lebih dapat diterima dibandingkan jumlah False Negative yang sangat tinggi pada QSVC, yaitu 40 sampel anomali yang gagal terdeteksi dan diklasifikasikan sebagai data normal. Sebaliknya, SVC Klasik mencatat hanya 19 False Negative, menurunkan risiko kegagalan deteksi dengan selisih 21 kasus.

Secara keseluruhan, visualisasi ini menegaskan bahwa SVC Klasik (Weighted) lebih andal dan lebih aman digunakan pada skenario yang membutuhkan deteksi anomali yang akurat. Tingginya False Negative pada QSVC menunjukkan risiko besar bagi sistem karena anomali yang tidak terdeteksi dapat menyebabkan dampak negatif yang serius. Oleh karena itu, SVC Klasik (Weighted) menjadi pilihan yang lebih tepat ketika tujuan utama adalah meminimalkan kegagalan deteksi anomali.

Grafik garis menunjukkan distribusi jumlah prediksi yang dihasilkan oleh model QSVC pada empat titik observasi atau kategori tertentu. Terlihat bahwa pada titik pertama, jumlah prediksi berada pada nilai yang sangat rendah. Selanjutnya, grafik memperlihatkan peningkatan signifikan pada titik kedua, dengan lonjakan jumlah prediksi mencapai kisaran tertinggi dalam grafik, yaitu sekitar 140 prediksi. Hal ini menandakan bahwa pada fase tersebut model QSVC lebih banyak menghasilkan output dibandingkan fase lainnya.

Namun, setelah mencapai puncak, jumlah prediksi menurun drastis pada titik ketiga hingga kembali mendekati nol. Penurunan tajam ini menggambarkan adanya perubahan karakteristik data atau kondisi model yang menyebabkan QSVC hampir tidak memberikan prediksi pada fase tersebut. Pada titik keempat, grafik menunjukkan kenaikan kembali meskipun tidak setinggi sebelumnya, dengan jumlah prediksi meningkat ke sekitar 40.

Secara keseluruhan, pola naik-turun yang ekstrem dalam grafik QSVC Count ini menunjukkan bahwa performa prediksi QSVC sangat dipengaruhi oleh variasi data pada setiap tahap. Fluktuasi besar dapat mengindikasikan sensitivitas QSVC terhadap distribusi fitur atau kemungkinan adanya concept drift pada data yang diuji. Oleh karena itu, grafik ini menjadi indikator penting untuk memahami konsistensi perilaku QSVC dalam menghasilkan prediksi pada setiap segmen evaluasi.



Gambar 4 Grafik Count confusion matrik

Gambar 4 Grafik garis menggambarkan jumlah prediksi yang dihasilkan oleh model SVC Klasik berbobot (Weighted) pada empat titik evaluasi atau kategori tertentu. Pada titik pertama, jumlah prediksi berada pada kisaran 20, menunjukkan aktivitas prediksi yang relatif rendah. Memasuki titik kedua, grafik mengalami peningkatan tajam hingga mencapai puncak sekitar 80 prediksi. Lonjakan ini menunjukkan bahwa model pada fase tersebut lebih aktif dalam menghasilkan keputusan klasifikasi, kemungkinan karena karakteristik data yang lebih sesuai dengan pola pembelajaran model.

Setelah mencapai titik tertinggi, grafik memperlihatkan penurunan bertahap pada titik ketiga, dengan jumlah prediksi berada di sekitar 60. Penurunan ini masih berada dalam rentang yang moderat, menandakan bahwa model tetap melakukan prediksi secara signifikan meskipun tidak seintens pada fase sebelumnya. Pada titik keempat, grafik turun lebih drastis hingga kembali ke kisaran 20, tingkat yang sebanding dengan fase awal.

Secara keseluruhan, pola fluktuasi pada grafik SVC Klasik (Weighted) Count menunjukkan respons model terhadap variasi data pada setiap segmen evaluasi. Perubahan jumlah prediksi yang lebih moderat dibandingkan QSVK menggambarkan bahwa model SVC klasik berbobot cenderung lebih stabil dalam menghasilkan output. Hal ini dapat mengindikasikan bahwa pendekatan pembobotan pada model memberikan kontribusi positif terhadap konsistensi prediksi, khususnya pada konteks data yang mengalami ketidakseimbangan kelas atau dinamika distribusi fitur. Grafik ini menjadi indikator penting dalam mengevaluasi pola kerja model dalam skenario data bertahap atau streaming.

CONCLUSION

Menyajikan kesimpulan utama yang diturunkan dari hasil eksperimen dan analisis yang dilakukan pada penelitian implementasi Quantum-Inspired Support Vector Machine (QSVK) untuk deteksi anomali lalu lintas

jaringan 5G. Selanjutnya disampaikan saran praktis dan rekomendasi penelitian lanjutan yang didasarkan pada keterbatasan eksperimen, temuan metrik performa, serta analisis kestabilan dan implikasi penerapan pada lingkungan nyata.

Berikut ini adalah kesimpulan dalam penelitian ini, antara lain :

Mengatasi keterbatasan SVM klasik Analisis eksperimen menunjukkan bahwa kelemahan utama SVM klasik pada konteks lalu lintas 5G adalah sensitivitas terhadap ketidakseimbangan kelas dan keterbatasan pemodelan fitur nonlinier pada skenario fitur berdimensi kompleks. Untuk kondisi dataset yang digunakan, konfigurasi SVC klasik berbobot mampu meningkatkan deteksi anomali dibandingkan SVM tanpa penyesuaian bobot, tetapi masih memerlukan pipeline pra-pemrosesan yang kuat (oversampling, fitur sintetis) agar performa stabil. Oleh karena itu, pendekatan praktis untuk mengatasi keterbatasan SVM klasik. Penerapan teknik penyeimbangan kelas (SMOTE / generative augmentation). Rekayasa fitur domain-aware dan reduksi dimensi terkontrol. Penyesuaian bobot kelas dan threshold kalibrasi pada fase inferensi. Kesimpulan ini menegaskan bahwa perbaikan pada tahap pra-pemrosesan dan strategi bobot lebih efektif sebelum beralih ke arsitektur model yang lebih kompleks.

Potensi dan batasan QSVK dalam meningkatkan deteksi anomali Eksperimen QSVK dengan ZZFeatureMap menunjukkan kemampuan untuk mencapai akurasi global yang tinggi namun, pada konfigurasi eksperimen tertentu, gagal mendeteksi sebagian besar anomali (recall anomali mendekati nol). Temuan ini mengindikasikan bahwa pemetaan fitur kuantum dapat meningkatkan kapasitas representasi, tetapi keberhasilan deteksi anomali bergantung pada desain feature map, ukuran sampel, dan penanganan ketidakseimbangan. Dengan kata lain, QSVK memiliki potensi untuk meningkatkan akurasi dan separabilitas fitur, namun tidak otomatis meningkatkan recall anomali tanpa kombinasi teknik penyeimbangan dan tuning hyperparameter. Oleh karena itu, QSVK direkomendasikan sebagai bagian dari pendekatan hibrida (quantum-inspired embedding + classifier klasik berbobot) yang pragmatis untuk meningkatkan deteksi anomali sambil mempertahankan efisiensi komputasi.

Integrasi QSVK dengan mekanisme pembelajaran adaptif Hasil validasi streaming dan analisis drift menunjukkan bahwa model statis (baik klasik maupun quantum-inspired) akan menurun performanya jika tidak ada mekanisme adaptif. Untuk merespons dinamika lalu lintas 5G, integrasi QSVK ke dalam kerangka pembelajaran adaptif diperlukan misalnya pembelajaran

inkremental, rolling-window retraining, dan monitoring concept drift. Implementasi QSVM dalam setting adaptif harus menggabungkan pipeline pra-pemrosesan yang dapat di-update (mis. skema sampling ulang), kalibrasi threshold otomatis, dan modul evaluasi online agar model mempertahankan sensitivitas terhadap anomali yang berevolusi.

REFERENCE

- [1] M. S. Wani, M. Rademacher, T. Horstmann, and M. Kretschmer, "Security Vulnerabilities in 5G Non-Stand-Alone Networks: A Systematic Analysis and Attack Taxonomy," *Journal of Cybersecurity and Privacy*, vol. 4, no. 1, pp. 23–40, 2024.
- [2] C. Mangla, S. Rani, N. M. F. Qureshi, and A. Singh, "Mitigating 5G security challenges for next-gen industry using quantum computing," *Journal of King Saud University — Computer and Information Sciences*, vol. 35, no. 6, p. 101334, 2023.
- [3] H. Yu, W. Yang, B. Cui, R. Sui, and X. Wu, "Enhanced anomaly traffic detection framework using BiGAN and contrastive learning," *Cybersecurity*, vol. 7, p. 71, 2024.
- [4] D. Segura, J. Munilla, E. J. Khatib, and R. Barco, "5G Early Data Transmission (Rel-16): Security Review and Open Issues," *IEEE Access*, vol. 10, pp. 93289–93308, 2022.
- [5] L. Akter, M. Islam Jabed, A. S. Khawer, S. Ferdous, and A. Gupta, "Quantum-Inspired Machine Learning for Zero-Trust Cybersecurity: A Paradigm beyond Classical Intrusion Detection," *International Journal of Intelligent Systems and Applications in Engineering*, vol. 12, no. 20s, pp. 1070–1080, 2024.
- [6] D. E. Tasar, K. Koruyan, and C. Öcal Coşar, "Machine Learning in the Quantum Age: Quantum vs. Classical Support Vector Machines," *Kuantum Teknolojileri ve Enformatik Araştırmaları Dergisi*, vol. 1, no. 1, pp. 65–72, 2023.