

H-QGQS: Kerangka Kerja Hybrid QGNN–QSVM untuk Prediksi Kinerja Publikasi Universitas Berbasis Data Scientometrik

H-QGQS: A Hybrid QGNN–QSVM Framework for Predicting University Publication Performance Using Scientometric Data

Lukman Anas^{a,c,1*}, Aghus Sofwan^{b,2}, Iwan Setiawan^{b,3}

^a Program Doktor Sistem Informasi, Sekolah Pascasarjana Universitas Diponegoro, Semarang, Indonesia

^b Jurusan Teknik Elektro, Universitas Diponegoro, Semarang, Indonesia

^c Informatika, Universitas Muhammadiyah Makassar, Makassar, Indonesia

¹lukmananas@unismuh.ac.id; ²asofwan@elektro.undip.ac.id; ³iwansetiawan@live.undip.ac.id;

*corresponding author

Informasi Artikel	ABSTRAK
Diserahkan : 11 Agustus 2026 Diterima : 30 Agustus 2026 Direvisi : 30 Agustus 2026 Diterbitkan : 31 Agustus 2026 Kata Kunci: H-QGQS QGNN QSVM Scientometrik Publikasi	Evaluasi kinerja publikasi universitas berbasis indikator scientometrik menghadapi tantangan karena data bersifat relasional, heterogen, dan nonlinier. Penelitian ini mengusulkan H-QGQS, kerangka hibrida yang mengintegrasikan Quantum Graph Neural Network (QGNN) dan Quantum Support Vector Machine (QSVM) untuk mengklasifikasikan kinerja publikasi universitas ke dalam kategori rendah, sedang, dan tinggi. Evaluasi dilakukan pada 3.818 rekaman dengan skenario eksperimen dari pendekatan klasik hingga berbasis kuantum. Hasil menunjukkan bahwa SVM (S-1) mencapai akurasi 0,92, sedangkan H-QGQS (S-3) memperoleh akurasi 0,73. Meskipun akurasi SVM lebih tinggi, H-QGQS menunjukkan potensi dalam merepresentasikan hubungan scientometrik yang kompleks dan mengidentifikasi universitas berkinerja tinggi. Temuan ini menegaskan peluang pemanfaatan quantum-enhanced graph learning untuk pemodelan scientometrik, meskipun masih diperlukan peningkatan pada arsitektur, fitur, efisiensi komputasi, dan skalabilitas model.
Keywords: H-QGQS QGNN QSVM Scientometric Publication This is an open access article under the CC-BY-SA license. 	ABSTRACT <i>Evaluating university publication performance based on scientometric indicators presents challenges due to the relational, heterogeneous, and non-linear nature of the data. This study proposes H-QGQS, a hybrid framework integrating Quantum Graph Neural Networks (QGNN) and Quantum Support Vector Machines (QSVM) to classify university publication performance into low, medium, and high categories. The evaluation was conducted on 3,818 records using experimental scenarios ranging from classical to quantum-based approaches. Results indicate that SVM (S-1) achieved an accuracy of 0.92, whereas H-QGQS (S-3) attained an accuracy of 0.73. Although SVM demonstrated higher accuracy, H-QGQS showed potential in representing complex scientometric relationships and identifying high-performing universities. These findings highlight the potential of utilizing quantum-enhanced graph learning for scientometric modeling, although further improvements to the architecture, features, computational efficiency, and model scalability are still required.</i>

I. Pendahuluan

Kinerja publikasi ilmiah merepresentasikan kapasitas riset, produktivitas akademik, dan reputasi universitas. Evaluasinya memanfaatkan indikator scientometrik seperti jumlah publikasi, sitasi, h-index, kuartil jurnal, dan Field-Weighted Citation Impact (FWCI) untuk menilai produktivitas serta dampak penelitian [1–3]. Seiring berkembangnya analitik data, machine learning dan deep learning telah digunakan untuk memodelkan publikasi dan dampak ilmiah [4,5], tetapi banyak pendekatan masih memperlakukan indikator sebagai fitur independen sehingga struktur relasional antarpengarang, institusi, publikasi, sitasi, jurnal, dan kolaborasi belum dimanfaatkan secara optimal.

Data scientometrik pada dasarnya membentuk jaringan kompleks dengan ketergantungan nonlinier. Graph Neural Network (GNN) memungkinkan pembelajaran langsung dari node dan edge, sedangkan Quantum

Machine Learning (QML) menawarkan representasi berdimensi tinggi melalui ruang fitur kuantum [6–8]. Kombinasi keduanya menjadi dasar pengembangan H-QGQS untuk memanfaatkan informasi numerik sekaligus struktur graf dalam klasifikasi kinerja publikasi universitas. Pada tahap klasifikasi, Quantum Support Vector Machine (QSVM) memperluas SVM melalui quantum kernel untuk memetakan data ke ruang Hilbert, sehingga hubungan nonlinier dapat direpresentasikan dengan transformasi fitur yang lebih kaya [9–11]. Sementara itu, GNN dirancang untuk data relasional dan efektif dalam mempelajari representasi berdasarkan hubungan antarentitas [12,13]. Quantum Graph Neural Network (QGNN) menggabungkan pembelajaran graf dan komputasi kuantum dengan memanfaatkan superposisi serta entanglement untuk merepresentasikan ketergantungan topologis yang kompleks [14,15].

Kajian scientometrik sebelumnya didominasi analisis bibliometrik, statistik jaringan, dan machine learning untuk jumlah publikasi, sitasi, produktivitas, serta prediksi dampak penelitian [16–19]. Pendekatan kuantum–klasik hibrida juga mulai dikembangkan pada berbagai tugas klasifikasi dan menunjukkan potensi dalam menghasilkan representasi fitur yang lebih ekspresif [20]. Namun, integrasi pembelajaran graf kuantum dengan klasifikasi kuantum untuk evaluasi kinerja publikasi institusional masih terbatas.

Penelitian ini mengusulkan Hybrid Quantum Graph Neural Network–Quantum Support Vector Machine (H-QGQS) untuk mengklasifikasikan kinerja publikasi Perguruan Tinggi Muhammadiyah dan ‘Aisyiyah (PTMA) ke dalam kategori Rendah, Sedang, dan Tinggi. QGNN digunakan untuk mempelajari representasi struktur relasional scientometrik, sedangkan QSVM memanfaatkan quantum kernel pada tahap klasifikasi. Kerangka ini dievaluasi melalui skenario ablasi dari pendekatan klasik hingga hibrida kuantum guna menilai kontribusi pembelajaran graf dan komponen kuantum.

Untuk mencapai tujuan tersebut, H-QGQS mengintegrasikan Quantum Graph Neural Network (QGNN) sebagai komponen pembelajaran representasi untuk menangkap struktur relasional dan pola topologis dalam data scientometrik, serta Quantum Support Vector Machine (QSVM) sebagai komponen klasifikasi yang memanfaatkan representasi pada ruang fitur kuantum. Integrasi kedua komponen tersebut memungkinkan eksplorasi hubungan antara struktur jaringan scientometrik dan karakteristik kinerja publikasi dalam satu kerangka pembelajaran hibrida. Dengan demikian, penelitian ini tidak hanya mengevaluasi kelayakan penerapan pendekatan kuantum pada klasifikasi kinerja publikasi, tetapi juga mengeksplorasi bagaimana informasi struktural pada jaringan scientometrik dapat diintegrasikan dengan mekanisme klasifikasi berbasis kuantum. Kerangka H-QGQS diharapkan dapat memberikan perspektif metodologis alternatif dalam analisis kinerja penelitian institusional, sekaligus menyediakan informasi yang relevan untuk mendukung evaluasi, perencanaan penelitian, dan pengembangan kebijakan pada lingkungan perguruan tinggi.


II. Metode

Dalam mengevaluasi kontribusi masing-masing komponen dalam model yang diusulkan, penelitian ini menerapkan desain eksperimen ablasi melalui empat skenario, yaitu S1–S4. Setiap skenario secara bertahap mengubah atau menghilangkan komponen tertentu dalam arsitektur model, sehingga pengaruh masing-masing komponen terhadap kinerja klasifikasi dapat diidentifikasi secara terukur. S1 digunakan sebagai konfigurasi dasar (*baseline*), sedangkan S2–S4 secara bertahap mengintegrasikan atau menguji komponen utama, yaitu representasi graf, QGNN, dan QSVM. Perbandingan hasil antar-skenario kemudian digunakan untuk mengetahui kontribusi setiap komponen serta memastikan bahwa peningkatan kinerja model berasal dari kombinasi komponen yang diusulkan, bukan semata-mata dari satu komponen tertentu.

Kontribusi setiap komponen dievaluasi melalui desain ablasi S1–S4. S1 menjadi baseline klasik, sedangkan skenario berikutnya secara bertahap memasukkan pembelajaran graf, QGNN, dan QSVM. Seluruh skenario menggunakan dataset dan pembagian data yang konsisten sehingga perubahan kinerja dapat dikaitkan dengan komponen model yang diuji.

A. Gambaran Umum Kerangka Penelitian

H-QGQS merupakan kerangka hibrida kuantum–klasik untuk klasifikasi kinerja publikasi berbasis data scientometrik. Alur penelitian meliputi pengumpulan dan pra-pemrosesan data, konstruksi graf, pembelajaran representasi dengan QGNN, klasifikasi menggunakan QSVM, serta evaluasi model seperti ditunjukkan pada Gambar 1. Data dibersihkan, ditransformasi, dinormalisasi, dan dipilih fiturnya sebelum direpresentasikan sebagai graf. Setiap institusi menjadi node dengan atribut scientometrik, sementara hubungan kolaborasi, sitasi, atau afiliasi membentuk edge. Representasi yang dihasilkan QGNN diteruskan ke QSVM untuk menentukan kelas kinerja publikasi.



Gambar 1. Diagram Penelitian

B. Pengumpulan dan Praproses Data

Data diperoleh dari Science and Technology Index (SINTA), yang mengintegrasikan informasi scientometrik dari Scopus, Web of Science (WoS), dan Google Scholar. Objek penelitian difokuskan pada PTMA, dengan indikator yang merepresentasikan produktivitas dan dampak publikasi sebagai dasar pembentukan fitur, graf, dan target klasifikasi. Tabel 1 menyajikan contoh data institusional SINTA yang diidentifikasi melalui ID SINTA dan kode afiliasi. Skor SINTA digunakan sebagai indikator agregat, sedangkan h-index Scopus, Google Scholar, dan WoS merepresentasikan dampak publikasi berdasarkan masing-masing sumber pengindeksan.

Tabel 1 menyajikan contoh data scientometrik yang diperoleh dari portal SINTA dan digunakan sebagai dasar analisis dalam penelitian. Setiap baris merepresentasikan satu entitas institusional Perguruan Tinggi Muhammadiyah dan 'Aisyiyah (PTMA) yang diidentifikasi melalui ID SINTA dan kode afiliasi. Atribut yang tersedia mencakup berbagai indikator kinerja publikasi yang bersumber dari sejumlah basis data ilmiah internasional. Skor SINTA digunakan sebagai indikator agregat untuk merepresentasikan kinerja penelitian institusi, sedangkan h-index dari Scopus, Google Scholar, dan Web of Science (WoS) digunakan untuk menggambarkan dampak publikasi berdasarkan karakteristik dan cakupan masing-masing sumber pengindeksan.

Tabel 1. Data Publikasi Ilmiah PTMA

SINTA ID	Affiliation Code	SINTA Score	h-index Scopus	h-index Google Scholar	h-index WoS	SINTA ID
23026	51013	11,061.70	26	35	13	23026
6672813	51013	4,433.25	20	26	7	6672813
23016	51013	6,707.19	11	30	4	23016
4547	61004	6,333.37	16	20	8	4547
5981297	91059	3,223.57	11	20	8	5981297
6176471	51013	2,749.51	17	18	16	6176471
5974494	51013	6,947.32	10	31	1	5974494
5986807	101002	3,629.02	15	33	8	5986807
23059	51013	6,263.12	5	23	4	23059
6774551	51013	2,910.50	—	—	—	6774551
5989087	61008	4,383.05	5	9	3	5989087
257453	31011	5,024.99	13	20	7	257453
6691487	91065	7,897.65	3	30	0	6691487

SINTA ID	Affiliation Code	SINTA Score	h-index Scopus	h-index Google Scholar	h-index WoS	SINTA ID
6001481	41087	2,743.63	6	11	10	6001481
257094	41061	6,516.30	30	32	20	257094
6000001	51007	2,178.12	12	14	4	6000001
23037	51013	3,980.55	8	14	6	23037
...	...	...	...	...	...	...
19,088	18083*	6,941,440	0	0	0	19,088

Hasil pra-pemrosesan ditransformasikan menjadi atribut node yang merepresentasikan kinerja publikasi masing-masing PTMA dan digunakan dalam konstruksi graf scientometrik

C. Pelabelan Kinerja Publikasi

Label kinerja ditetapkan berdasarkan distribusi skor SINTA institusional menjadi tiga kelas: Rendah, Sedang, dan Tinggi.

Ambang berbasis tertill digunakan untuk membentuk kelas yang relatif seimbang: skor 0–3.200 sebagai Rendah, 3.201–6.400 sebagai Sedang, dan >6.400 sebagai Tinggi. Skema ini menjadi target klasifikasi multikelas pada tahap pelatihan dan evaluasi.

D. Kontruksi Graph Scientometrik

Setelah pra-pemrosesan, data ditransformasikan menjadi graf scientometrik $G=(V,E)$, dengan V sebagai himpunan institusi dan E sebagai relasi ilmiah antarinstansi.

$$G = (V, E) \quad (1)$$

Setiap node merepresentasikan PTMA dan memiliki vektor fitur scientometrik yang telah dinormalisasi. Edge menggambarkan keterkaitan melalui publikasi bersama, sitasi, atau afiliasi lintas institusi. Fitur node mencakup jumlah publikasi, jumlah sitasi, h-index Scopus/Google Scholar/WoS, dan skor SINTA institusional. $v_i \in V$.

E. Pembelajaran Representasi Menggunakan QGNN

QGNN digunakan untuk mengekstrak informasi struktural laten dari graf. Matriks fitur node dan adjacency menjadi input, lalu fitur klasik dipetakan ke keadaan kuantum menggunakan angle encoding. Implementasi menggunakan 6 qubit dan ansatz berparameter dengan gerbang rotasi serta CNOT untuk memodelkan korelasi antarfitur dan hubungan antarnode. $G = (V, E) \times A v_i x_i$, Proses QGNN terdiri atas empat tahap utama sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Tahapan QGNN

Pertama, Quantum Encoding memetakan enam fitur scientometrik ternormalisasi ke sudut rotasi pada 6 qubit. Kedua, Quantum Message Passing menyebarkan informasi antarnode yang terhubung melalui operasi kuantum berparameter. Ketiga, Quantum Aggregation and Transformation menggabungkan pesan tetangga menggunakan tiga lapisan variasi Ry/Rz dan keterikatan CNOT linier. Keempat, Measurement and Embedding memproyeksikan keadaan kuantum kembali ke ruang klasik melalui nilai harapan qubit untuk menghasilkan embedding node. QGNN dilatih dengan optimizer Adam (learning rate 0,001) selama 100 epoch. Sirkuit diimplementasikan menggunakan Qiskit Machine Learning dan Qiskit Aer state-vector simulator. Embedding node yang dihasilkan digunakan sebagai input pada tahap klasifikasi.

F. Klasifikasi Kinerja Publikasi Menggunakan QSVM

QSVM mengklasifikasikan embedding QGNN dengan memanfaatkan quantum kernel. Embedding dikodekan ke keadaan kuantum melalui feature map berparameter, kemudian kemiripan antaremboding dihitung pada ruang fitur kuantum. Kernel tersebut digunakan SVM untuk menentukan hyperplane pemisah kelas Rendah, Sedang, dan Tinggi.

$$|\phi(z_i)\rangle = U(z_i) |0\rangle \quad (2)$$

Pada Persamaan (2), embedding institusi dipetakan oleh parameterized quantum circuit (PQC) dari keadaan dasar qubit. Kemiripan dua embedding selanjutnya dihitung menggunakan quantum kernel pada Persamaan (3).

$$K(z_i, z_j) = |\langle \phi(z_i) | \phi(z_j) \rangle|^2 \quad (3)$$

Berdasarkan quantum kernel tersebut, QSVM membentuk fungsi keputusan pada Persamaan (4) untuk memperoleh hyperplane optimal antar kelas.

$$f(z) = \sum_{i=1}^N a_i y_i K(z_i, z) + b \quad (4)$$

Koefisien support vector, label kelas, dan bias membentuk fungsi keputusan QSVM yang menghasilkan prediksi kinerja publikasi.

G. Evaluasi Prediksi Model

Dataset dibagi 80:20 untuk pelatihan dan pengujian. Kinerja model dievaluasi menggunakan confusion matrix serta metrik akurasi, presisi, recall, dan F1-score. Akurasi mengukur proporsi prediksi benar (Persamaan 5), presisi menilai ketepatan prediksi positif (Persamaan 6), recall mengukur kemampuan menemukan kasus positif aktual (Persamaan 7), dan F1-score merupakan rata-rata harmonis presisi dan recall (Persamaan 8).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (8)$$

III. Hasil dan Pembahasan

Eksperimen mengevaluasi kemampuan H-QGQS dalam mengenali pola scientometrik dan membandingkan pembelajaran berbasis fitur, graf, dan komponen kuantum.

A. Skenario Exprimental


Seluruh skenario menggunakan 3.818 rekaman hasil pra-pemrosesan dan penyeimbangan kelas dengan pembagian data yang konsisten. S1 menggunakan fitur klasik dan SVM; S2 menguji representasi graf klasik; S3 menggunakan QGNN dengan SVM klasik; dan S4 mengintegrasikan QGNN dengan QSVM. Pada S1, indikator scientometrik direpresentasikan sebagai vektor fitur dan diklasifikasikan menggunakan SVM sebagai baseline. Hasilnya disajikan pada Tabel 2.

Tabel 2. Prediksi Indikator Scientometric Menggunakan SVM

Class	Precision	Recall	F1-Score	Support
Tinggi	0,98	0,95	0,96	1.272


Rendah	0,89	0,95	0,92	1.274
Sedang	0,89	0,86	0,88	1.272
Accuracy			0,92	3.818

SVM mencapai akurasi 0,92. Kelas Tinggi memperoleh presisi 0,98 dan F1-score 0,96, sedangkan kelas Rendah memiliki recall 0,95. Kelas Sedang menjadi yang paling sulit dibedakan dengan recall 0,86. Confusion matrix pada Gambar 3 menunjukkan bahwa kesalahan terutama terjadi pada kelas Sedang, mengindikasikan tumpang tindih karakteristik scientometrik antar kelas.



Gambar 3. Confusion Matrix SVM

Pada S2, data direpresentasikan sebagai graf dengan institusi sebagai node dan hubungan kolaborasi atau sitasi sebagai edge. GNN klasik menghasilkan node embedding yang kemudian diklasifikasikan menggunakan SVM. Skenario ini mengisolasi kontribusi pembelajaran graf tanpa komponen kuantum; representasinya ditunjukkan pada Gambar 4.




Gambar 4. Representasi Graph Scientometrik

Visualisasi graf memperlihatkan node berkinerja Tinggi cenderung lebih sentral dan terhubung padat, sedangkan kelas Rendah lebih tersebar di perifer. Kelas Sedang berada pada posisi transisi dan memiliki kemiripan dengan kedua kelas ekstrem. Pola ini menunjukkan bahwa struktur graf memberikan konteks relasional yang tidak tersedia pada representasi fitur independen. Pada S3, QGNN digunakan untuk menghasilkan embedding kuantum yang kemudian diklasifikasikan oleh SVM klasik. Hasil evaluasi QGNN Embedding-SVM ditunjukkan pada Tabel 3. Kehadiran kelompok warna yang berdekatan menunjukkan bahwa pembelajaran berbasis grafik dapat menangkap pola relasional dan struktur topologi yang tidak dapat dimodelkan oleh metode pembelajaran mesin konvensional. Oleh karena itu, visualisasi ini mendukung temuan kuantitatif bahwa representasi grafik menambahkan konteks yang relevan dalam menganalisis kinerja publikasi pendidikan tinggi. Selain itu, pada skenario ketiga (S3), Jaringan Neural Graf Kuantum (QGNN) digunakan untuk mempelajari penyematan graf scientometrik, sementara klasifikasi dilakukan dengan Mesin Vektor Pendukung (SVM) klasik. Tidak seperti skenario S2, yang menggunakan GNN konvensional, S3 mengadopsi prinsip Pembelajaran Mesin Kuantum (QML) untuk menghasilkan representasi graf.

Tabel 3. Evaluasi Kinerja Model QGNN Yang menggabungkan SVM

Class	Precision	Recall	F1-Score	Support
Tinggi	0,73	0,80	0,76	1.272
Rendah	0,80	0,80	0,80	1.272
Sedang	0,78	0,70	0,74	1.272
Accuracy			0,77	3.818

Model QGNN–SVM mencapai akurasi 0,77. Kelas Rendah paling konsisten dengan presisi, recall, dan F1-score sebesar 0,80. Kelas Tinggi memiliki recall 0,80 dan presisi 0,73, sedangkan kelas Sedang memperoleh F1-score terendah sebesar 0,74. Hasil ini menunjukkan bahwa embedding QGNN menangkap struktur relasional, tetapi pemisahan kelas belum sebaik baseline SVM.



Gambar 5. Embedding QGNN

Visualisasi embedding QGNN yang direduksi dengan PCA menunjukkan kelas Rendah membentuk kluster relatif padat, kelas Tinggi lebih menyebar, dan kelas Sedang tumpang tindih dengan kelas lain. Pola tersebut konsisten dengan perbedaan metrik klasifikasi pada Tabel 3. Pada S4, embedding QGNN diklasifikasikan menggunakan QSVM dengan quantum kernel sehingga tahap representasi dan klasifikasi sama-sama memanfaatkan komponen QML. Skenario ini mengevaluasi konfigurasi H-QGQS lengkap dan hasilnya disajikan pada Tabel 4.


Tabel 4. Evaluasi Kinerja Model QGNN dan QSVM

Class	Precision	Recall	F1-Score	Support
Rendah (0)	0,900	0,600	0,721	1.272
Sedang (1)	0,538	0,700	0,609	1.272
Tinggi (2)	0,733	0,906	0,808	1.272
Accuracy			0,73	3.818

H-QGQS (QGNN–QSVM) mencapai akurasi 0,73. Kinerja per kelas menunjukkan variasi yang cukup jelas. Kelas Rendah memiliki presisi 0,900, recall 0,600, dan F1-score 0,721, menunjukkan prediksi positif yang tepat tetapi masih melewatkan sebagian instance aktual. Kelas Sedang memperoleh presisi 0,538, recall 0,700, dan F1-score 0,609, sehingga tetap menjadi kelas yang paling sulit dibedakan karena tumpang tindih fitur dengan kelas lain.

Kelas Tinggi menunjukkan hasil terbaik dengan recall 0,906, presisi 0,733, dan F1-score 0,808. Hal ini menunjukkan kemampuan H-QGQS yang relatif kuat dalam mengidentifikasi institusi berkinerja tinggi.

Secara keseluruhan, integrasi QGNN dan QSVM memberikan kemampuan diskriminatif terutama pada kelas Tinggi, tetapi akurasi agregat masih di bawah SVM klasik. Confusion matrix hasil S4 ditunjukkan pada Gambar 6.



Gambar 6. Confusion Matrix QGNN Embedding QSVM

Hasil eksperimen menunjukkan bahwa pendekatan kuantum belum melampaui SVM klasik pada dataset saat ini. SVM mencapai akurasi 0,92 dengan implementasi dan kebutuhan komputasi yang lebih sederhana, sedangkan QGNN-SVM mencapai 0,77 dan H-QGQS 0,73. Karena itu, penggunaan komponen kuantum belum dapat dibenarkan berdasarkan peningkatan akurasi semata. Potensinya lebih relevan untuk data yang lebih besar, relasi yang lebih kompleks, atau ruang fitur berdimensi tinggi yang menantang metode klasik.

S1 menunjukkan bahwa indikator scientometrik numerik telah mengandung informasi kuat untuk membedakan kinerja institusi, tetapi tidak menangkap relasi eksplisit. S2 menambahkan pembelajaran graf untuk memodelkan konteks antarlembaga; pendekatan GNN diketahui efektif pada data heterogen dan berbasis jaringan [21],[22]. S3 memperluas pembelajaran relasional melalui QGNN dengan pengkodean fitur ke ruang kuantum, sementara klasifikasi tetap menggunakan SVM klasik. Konfigurasi hibrida seperti ini merupakan salah satu jalur untuk menggabungkan pembelajaran graf dan QML [23], [24]. S4 mengintegrasikan QGNN dengan QSVM dan mencapai akurasi 0,73. Kelas Tinggi memiliki recall 0,906 dan F1-score 0,808, sedangkan kelas Sedang tetap paling ambigu. QSVM berpotensi membantu pada distribusi data kompleks dan nonlinier dalam ruang fitur berdimensi tinggi [25], [26]. Temuan keseluruhan menunjukkan bahwa pembelajaran graf dan representasi kuantum menawarkan perspektif alternatif untuk menangkap struktur scientometrik, tetapi masih memerlukan optimasi arsitektur, fitur, dan skala data

IV. Kesimpulan dan saran

Hasil eksperimen menunjukkan bahwa pendekatan kuantum belum melampaui SVM klasik pada dataset saat ini. SVM mencapai akurasi 0,92 dengan implementasi dan kebutuhan komputasi yang lebih sederhana, sedangkan QGNN-SVM mencapai 0,77 dan H-QGQS 0,73. Karena itu, penggunaan komponen kuantum belum dapat dibenarkan berdasarkan peningkatan akurasi semata. Potensinya lebih relevan untuk data yang lebih besar, relasi yang lebih kompleks, atau ruang fitur berdimensi tinggi yang menantang metode klasik. S1 menunjukkan bahwa indikator scientometrik numerik telah mengandung informasi kuat untuk membedakan kinerja institusi, tetapi tidak menangkap relasi eksplisit. S2 menambahkan pembelajaran graf untuk memodelkan konteks antarlembaga; pendekatan GNN diketahui efektif pada data heterogen dan berbasis jaringan [21],[22]. S3 memperluas pembelajaran relasional melalui QGNN dengan pengkodean fitur ke ruang kuantum, sementara klasifikasi tetap menggunakan SVM klasik. Konfigurasi hibrida seperti ini merupakan salah satu jalur untuk menggabungkan pembelajaran graf dan QML [23], [24]. S4 mengintegrasikan QGNN dengan QSVM dan mencapai akurasi 0,73. Kelas Tinggi memiliki recall 0,906 dan F1-score 0,808, sedangkan kelas Sedang tetap paling ambigu. QSVM berpotensi membantu pada distribusi data kompleks dan nonlinier dalam ruang fitur berdimensi tinggi [25], [26]. Temuan keseluruhan menunjukkan bahwa pembelajaran graf dan representasi kuantum menawarkan perspektif alternatif untuk menangkap struktur scientometrik, tetapi masih memerlukan optimasi arsitektur, fitur, dan skala data

Daftar Pustaka

- [1] F. Mayta-Tovalino *et al.* , “Evaluasi saintometrik tren dan karakteristik global penelitian yang dipublikasikan tentang kesehatan masyarakat kerja,” *Heliyon* , vol. 8, no. 12, hal. e12165, 2022, doi: 10.1016/j.heliyon.2022.e12165.
- [2] N. Scelles dan JA Teixeira da Silva, “Membuat dampak publikasi dalam suatu bidang sebanding dengan meningkatkan dampak sitasi tertimbang bidang (FWCI): kasus manajemen olahraga,”

- Scientometrics* , vol. 130, no. 3, hlm. 1571–1586, 2025, doi: 10.1007/s11192-025-05268-4.
- [3] F. Emmert-Streib, S. Tripathi, A. Farea, dan O. Yli-Harja, “Analisis Saintometrik Lanjutan Pembelajaran Mesin Ilmiah dan PINN: Pemodelan Topik dan Analisis Tren,” *IEEE Access* , vol. 12, no. Agustus, hlm. 153253–153272, 2024, doi: 10.1109/ACCESS.2024.3481671.
 - [4] M. Daradkeh, L. Abualigah, S. Atalla, dan W. Mansoor, “Analisis dan Klasifikasi Penelitian Saintometrik Menggunakan Jaringan Saraf Konvolusional: Studi Kasus dalam Ilmu Data dan Analitik,” *Electron.* , vol. 11, no. 13, 2022, doi: 10.3390/electronics11132066.
 - [5] P. Lamichhane dan DB Rawat, “Pembelajaran Mesin Kuantum: Kemajuan, Tantangan, dan Perspektif Terkini,” *IEEE Access* , vol. 13, hlm. 94057–94105, 2025, doi: 10.1109/ACCESS.2025.3573244.
 - [6] F. Rodríguez-Díaz, D. Gutiérrez-Avilés, A. Troncoso, dan F. Martínez-Álvarez, “Survei Pembelajaran Mesin Kuantum: Landasan, Algoritma, Kerangka Kerja, Data dan Aplikasi,” *ACM Comput. Bertahan.* , jilid. 58, tidak. 4, hlm. 1–35, 2026, doi: 10.1145/3764582.
 - [7] D. Ranga, A. Rana, S. Prajapat, P. Kumar, K. Kumar, dan AV Vasilakos, “Pembelajaran Mesin Kuantum: Menjelajahi Peran Teknik Pengkodean Data, Tantangan, dan Arah Masa Depan,” *Matematika* , vol. 12, no. 21, hlm. 1–32, 2024, doi: 10.3390/math12213318.
 - [8] L. Anas, A. Sofwan, dan I. Setiawan, “Model Identifikasi Peneliti Berbakat Berdasarkan Indikator Saintometrik dengan Pendekatan Pembelajaran Mesin Kuantum (QML) BT - Prosiding Analisis dan Manajemen Data,” A. Swaroop, B. Virdee, SD Correia, dan Z. Polkowski, Eds., Cham: Springer Nature Switzerland, 2025, hlm. 340–350. doi: 10.1007/978-3-032-03072-6_27.
 - [9] M. Faisal *et al.*, “Utilizing Machine Learning-Based Decision-Making to Align Higher Education Curriculum with Industry Requirements,” *Int. J. Mod. Educ. Comput. Sci.*, vol. 17, no. 4, pp. 1–25, Aug. 2025, doi: 10.5815/ijmecs.2025.04.01.
 - [10] S. Piperno, A. Ceschini, SY Chang, M. Grossi, S. Vallecorsa, dan M. Panella, “Studi tentang jaringan saraf grafik kuantum yang diterapkan pada fisika molekuler,” *Phys. Scr.* , vol. 100, no. 6, 2025, doi: 10.1088/1402-4896/add8e9.
 - [11] N. Donthu, S. Kumar, D. Mukherjee, N. Pandey, dan WM Lim, “Cara melakukan analisis bibliometrik: Tinjauan umum dan pedoman,” *J. Bus. Res.* , vol. 133, no. Maret, hlm. 285–296, 2021, doi: 10.1016/j.jbusres.2021.04.070.
 - [12] R. Kumar, “Analisis Bibliometrik: Wawasan Komprehensif tentang Alat, Teknik, Aplikasi, dan Solusi untuk Keunggulan Penelitian,” *Spectr. Eng. Manag. Sci.* , vol. 3, no. 1, hlm. 45–62, 2025, doi: 10.31181/sems31202535k.
 - [13] M. Faisal *et al.*, “Assessing AI-Driven Personalization in Smart Cities Using Hybrid Machine Learning and MCDM Approach,” *HighTech Innov. J.*, vol. 6, no. 3, pp. 770–792, Sep. 2025, doi: 10.28991/HIJ-2025-06-03-03
 - [14] YA Alohal, MS Fayed, T. Mesallam, Y. Abdelsamad, F. Almuhawes, dan A. Hagr, “Model Pembelajaran Mesin untuk Memprediksi Jumlah Sitasi Makalah Ilmiah di Bidang Otologi,” *Biomed Res. Int.* , vol. 2022, 2022, doi: 10.1155/2022/2239152.
 - [15] VM Venkatappa dan . Venkateshappa, “Jaringan Neural Konvolusi Kuantum Baru untuk Aplikasi Klasifikasi Gambar,” *Eng. Technol. Appl. Sci. Res.* , vol. 15, no. 5, hlm. 27046–27051, 2025, doi: 10.48084/etasr.12416.
 - [16] C. García-Villar dan JM García-Santos, “Indikator bibliometrik untuk mengevaluasi aktivitas ilmiah,” *Radiol. (Edisi Bahasa Inggris)* , vol. 63, no. 3, hlm. 228–235, 2021, doi: <https://doi.org/10.1016/j.rxeng.2021.01.002>.
 - [17] J. Zhou *dkk.* , “Jaringan saraf graf: Tinjauan metode dan aplikasi,” *AI Open* , vol. 1, no. Desember 2020, hlm. 57–81, 2020, doi: 10.1016/j.aiopen.2021.01.001.
 - [18] XM Zhang, L. Liang, L. Liu, dan MJ Tang, “Jaringan Neural Graf dan Aplikasi Terkininya dalam Bioinformatika,” *Front. Genet.* , vol. 12, no. Juli, hlm. 1–22, 2021, doi: 10.3389/fgene.2021.690049.
 - [19] L. Xu, XY Zhang, M. Li, dan SQ Shen, “Mesin vektor pendukung kuantum untuk klasifikasi multi,” *Commun. Theor. Phys.* , vol. 76, no. 7, hlm. 1–8, 2024, doi: 10.1088/1572-9494/ad48fc.
 - [20] D. Alaminos, MB Salas, dan MA Fernández-Gámez, “Metode Komputasi Kuantum dan Pembelajaran Mendalam untuk Peramalan Pertumbuhan PDB,” *Comput. Econ.* , vol. 59, no. 2, hlm. 803–829, 2022, doi: 10.1007/s10614-021-10110-z.
 - [21] T. Hoang, “GNN: Graph Neural Network and Large Language Model for Data Discovery,” hlm. 1–7,

- 2024, doi: 10.48550/arXiv.2408.13609.
- [22] B. Khemani, S. Patil, K. Kotecha, dan S. Tanwar, “Tinjauan jaringan saraf graf: konsep, arsitektur, teknik, tantangan, kumpulan data, aplikasi, dan arah masa depan,” *J. Big Data*, vol. 11, no. 1, 2024, doi: 10.1186/s40537-023-00876-4.
- [23] H. Salloum, A. Salloum, M. Mazzara, and S. Zykov, “Quantum Annealing in Machine Learning: QBoost on D-Wave Quantum Annealer,” *Procedia Comput. Sci.*, vol. 246, no. C, pp. 3285–3293, 2024, doi: 10.1016/j.procs.2024.09.311.
- [24] C. Zhang, “Multi-phase and multi-scale engine wear modeling via quantum chemical molecular dynamics and machine learning: A theoretical framework,” *Wear*, vol. 571, p. 205771, Jun. 2025, doi: 10.1016/j.wear.2025.205771.
- [25] T. Yin, “Mesin vektor pendukung kuantum: teori dan aplikasi,” dalam *Prosiding Lokakarya CONF-MPCS 2024*, 2024, hlm. 34–42. doi: 10.54254/2753-8818/51/2024CH0158.
- [26] D. Sharma, VB Sabale, P. Singh, dan A. Kumar, “Memanfaatkan mesin vektor pendukung kuantum untuk klasifikasi lintas domain keadaan kuantum,” *Quantum Mach. Intell.*, vol. 7, no. 1, hlm. 1–9, 2025, doi: 10.1007/s42484-025-00274-4.