

Analisis Komparatif Efisiensi Parameter *Hybrid Quantum-Classical Neural Network* pada Prediksi Energi Molekul QM9

Fahmi Izhari
UIN Syekh Ali Hasan Ahmad Addary Padangsidempuan
fahmi_izhari@uinsyahada.ac.id

Submit : 30 Nov 2025 | Diterima : 25 Des 2025 | Terbit : 28 Des 2025

ABSTRAK

Percepatan penemuan material baru terkendala oleh tingginya biaya komputasi metode kimia quantum konvensional seperti DFT (*Density Functional Theory*). Meskipun metode *Deep Learning* klasik menawarkan alternatif yang lebih cepat, pendekatan ini sering kali membutuhkan arsitektur dengan jutaan parameter untuk mencapai akurasi yang memadai. Penelitian ini mengevaluasi potensi *Quantum Machine Learning* (QML) untuk mengatasi masalah inefisiensi parameter tersebut. Secara spesifik, penelitian ini membandingkan kinerja model *Hybrid Quantum Neural Network* (HQNN) berbasis sirkuit variasional 4-qubit melawan model *Classical Multi-Layer Perceptron* (MLP) sebagai *baseline* pada tugas regresi energi internal (\$U_0\$) menggunakan dataset QM9. Untuk memastikan perbandingan yang adil, kedua model dibatasi secara ketat memiliki jumlah parameter yang identik, yaitu sekitar 72 parameter. Hasil eksperimen menunjukkan bahwa model Quantum mencapai konvergensi pelatihan yang lebih baik dengan nilai *Mean Squared Error* (MSE) akhir sebesar **0.6292**, mengungguli model Klasik yang berhenti di angka **0.7369**. Lebih lanjut, model Quantum mencatatkan akurasi prediksi dengan *Mean Absolute Error* (MAE) sebesar **759.89 Hartree**. Temuan ini membuktikan bahwa fitur *quantum entanglement* memberikan daya ekspresi (*expressibility*) yang superior dibandingkan transformasi linear klasik pada batasan sumber daya komputasi yang ketat, menjadikan algoritma hibrida quantum solusi yang menjanjikan untuk simulasi kimia di era *Noisy Intermediate-Scale Quantum* (NISQ).

Kata Kunci: *Hybrid Quantum Neural Network*, *Variational Quantum Circuit*, QM9 Dataset, Efisiensi Parameter, Prediksi Energi Molekul.

PENDAHULUAN

Percepatan penemuan material baru dan obat-obatan sangat bergantung pada kemampuan untuk memetakan ruang senyawa kimia (*chemical compound space*) yang diperkirakan mencakup lebih dari 10^{60} struktur molekul (Gangwal & Lavecchia, 2025). Metode komputasi klasik berbasis prinsip pertama (*ab initio*), seperti *Density Functional Theory* (DFT), telah lama menjadi standar emas dalam memprediksi properti molekul (Mihaylov dkk., 2021). Namun, kompleksitas komputasi DFT yang meningkat secara eksponensial terhadap jumlah elektron membatasi penerapannya pada skala besar (Dawson dkk., 2022). Sebagai alternatif, pendekatan *Machine Learning* (ML) klasik, seperti *Message Passing Neural Networks* (MPNN), telah berhasil memprediksi properti kimia dengan akurasi yang mendekati DFT namun dengan kecepatan jutaan kali lebih tinggi (Karthikeyan & Priyakumar, 2022; Liyaqat dkk., 2025; Niazi & Mariam, 2023).

Meskipun demikian, (Avramouli dkk., 2023) dalam jurnalnya mengatakan bahwa

model *Deep Learning* klasik sering kali membutuhkan dataset yang sangat besar dan jutaan parameter untuk menangkap korelasi quantum yang kompleks antar-atom. Hal ini memicu minat besar terhadap Komputasi Quantum. Hipotesis Feynman dalam penelitian (Rietsche dkk., 2022) menyatakan bahwa sistem quantum alamiah paling efektif disimulasikan oleh komputer yang beroperasi berdasarkan prinsip mekanika quantum. Pada era *Noisy Intermediate Scale Quantum* (NISQ) saat ini, *Quantum Machine Learning* (QML) muncul sebagai paradigma baru yang menjanjikan efisiensi parameter yang lebih tinggi dibandingkan jaringan saraf klasik (Lamichhane & Rawat, 2025).

Pendekatan hibrida klasik quantum, khususnya *Variational Quantum Algorithms* (VQA), telah menjadi strategi utama untuk memanfaatkan perangkat keras quantum saat ini yang memiliki jumlah qubit terbatas (Cerezo dkk., 2021). Peruzzo dalam penelitian (Hakim dkk., 2024) memperkenalkan *Variational Quantum Eigensolver* (VQE) yang menjadi fondasi bagi banyak aplikasi kimia quantum modern. Dalam konteks pembelajaran mesin, (Bai & Ran, 2025) mengembangkan *Quantum Circuit Learning* (QCL) yang menunjukkan bahwa sirkuit quantum dapat mempelajari fungsi non-linear yang kompleks.

(Macaluso, 2024) dalam penelitiannya mengatakan bahwa keunggulan teoritis QML terletak pada kemampuannya menggunakan ruang Hilbert berdimensi tinggi sebagai *feature space*. Macaluso mendemonstrasikan bahwa *quantum kernel methods* dapat memberikan keuntungan komputasi pada tugas klasifikasi yang sulit dilakukan oleh komputer klasik. Lebih lanjut, (Tacchino dkk., 2021) menjelaskan bahwa sirkuit quantum variasional pada dasarnya bekerja mirip dengan jaringan saraf, namun dengan transformasi fitur yang memanfaatkan fenomena *entanglement* dan *superposition*. Arsitektur sirkuit yang diparameterisasi (*Parameterized Quantum Circuits*) memiliki daya ekspresi (*expressibility*) yang unik untuk memodelkan distribusi data yang kompleks (Hubregtsen dkk., 2021).

Namun, tantangan utama dalam QML adalah merancang *ansatz* atau arsitektur sirkuit yang efisien. (Karuppasamy dkk., 2025), menyoroti pentingnya desain sirkuit yang spesifik untuk masalah kimia guna mengurangi kedalaman sirkuit dan memitigasi *noise*. Studi terbaru oleh (Kübler dkk., 2021), juga menunjukkan pentingnya *inductive bias* dalam model quantum untuk mencapai keunggulan dibandingkan model klasik pada dataset kecil hingga menengah.

Penelitian ini bertujuan untuk mengevaluasi efisiensi parameter dari *Hybrid Quantum-Classical Neural Network* pada tugas regresi dataset QM9 (Ramakrishnan dkk., 2014; Ruddigkeit dkk., 2012). Dengan mengintegrasikan temuan dari studi terdahulu, penelitian ini mengusulkan arsitektur sirkuit dengan topologi *entanglement* cincin untuk memprediksi energi internal (U_0) molekul, dan membandingkannya secara langsung dengan model klasik baseline untuk memvalidasi hipotesis efisiensi parameter.

TINJAUAN PUSTAKA

Prediksi Properti Molekul dan Dataset QM9

Prediksi properti termodinamika molekul secara akurat merupakan domain krusial dalam informatika kimia. Metode *ab initio* seperti *Density Functional Theory* (DFT) bekerja dengan memecahkan persamaan Schrödinger untuk sistem banyak elektron. Meskipun akurat, DFT memiliki kompleksitas komputasi yang tinggi, umumnya berskala $O(N^3)$ terhadap jumlah fungsi basis, menjadikannya tidak praktis untuk eksplorasi ruang kimia yang luas.

Sebagai standar evaluasi model komputasi, Ramakrishnan, Dral, Rupp, dan von Lilienfeld mempublikasikan dataset QM9. Dataset ini memuat data geometris, energetik, dan elektronik dari 133.885 molekul organik stabil yang terdiri dari atom C, H, O, N, dan

F. Variabel target utama dalam banyak penelitian, termasuk penelitian ini, adalah energi internal (U_0) pada 298.15 K, yang merepresentasikan stabilitas termodinamika molekul.

Keterbatasan *Classical Deep Learning* (GNN dan MPNN)

Pendekatan *Deep Learning* klasik telah diterapkan untuk memprediksi properti QM9. (Tang dkk., 2023), memperkenalkan *Neural Message Passing* (MPNN) yang memodelkan molekul sebagai graf. Model ini bekerja dengan menyebarkan informasi antar node (atom) melalui *edge* (ikatan) secara iteratif. Meskipun MPNN mampu mencapai *Mean Absolute Error* (MAE) yang kompetitif terhadap akurasi kimia (~ 1 kcal/mol), model ini membutuhkan arsitektur yang sangat dalam dengan jutaan parameter untuk menangkap interaksi jarak jauh antar atom. Ketergantungan pada jumlah parameter yang besar ini berisiko menyebabkan *overfitting* pada dataset yang lebih kecil dan inefisiensi memori.

Paradigma *Quantum Machine Learning* (QML)

Komputasi quantum menawarkan ruang fitur (*feature space*) yang secara eksponensial lebih besar dibandingkan komputasi klasik melalui prinsip superposisi dan *entanglement*. (Tychola dkk., 2023), mendefinisikan *Quantum Machine Learning* sebagai integrasi algoritma quantum dalam program pembelajaran mesin untuk memproses data.

Pada era NISQ (*Noisy Intermediate-Scale Quantum*), pendekatan yang paling layak diterapkan adalah algoritma hibrida klasik-quantum. Mekanisme *Variational Quantum Algorithms* (VQA), di mana sirkuit quantum yang terparameterisasi (*Parameterized Quantum Circuit* - PQC) bertindak sebagai pengganti lapisan *Neural Network*.

Sirkuit Variasional dan *Expressibility*

Inti dari VQA adalah ansatz atau arsitektur sirkuit. PQC dapat dianggap sebagai model generatif yang memetakan data input ke dalam ruang Hilbert yang kompleks (Yu dkk., 2024).

1. *Encoding* data klasik dikonversi ke *state* quantum, misalnya menggunakan rotasi qubit $R_Y(\theta)$ (Sierra-Sosa dkk., 2023).
2. *Entanglement* yakni penggunaan gerbang CNOT menciptakan korelasi non-lokal antar qubit, yang menurut He dkk. (2025) memungkinkan model quantum untuk menangkap pola data yang sangat non-linear dengan jumlah parameter yang jauh lebih sedikit dibandingkan perseptron klasik.

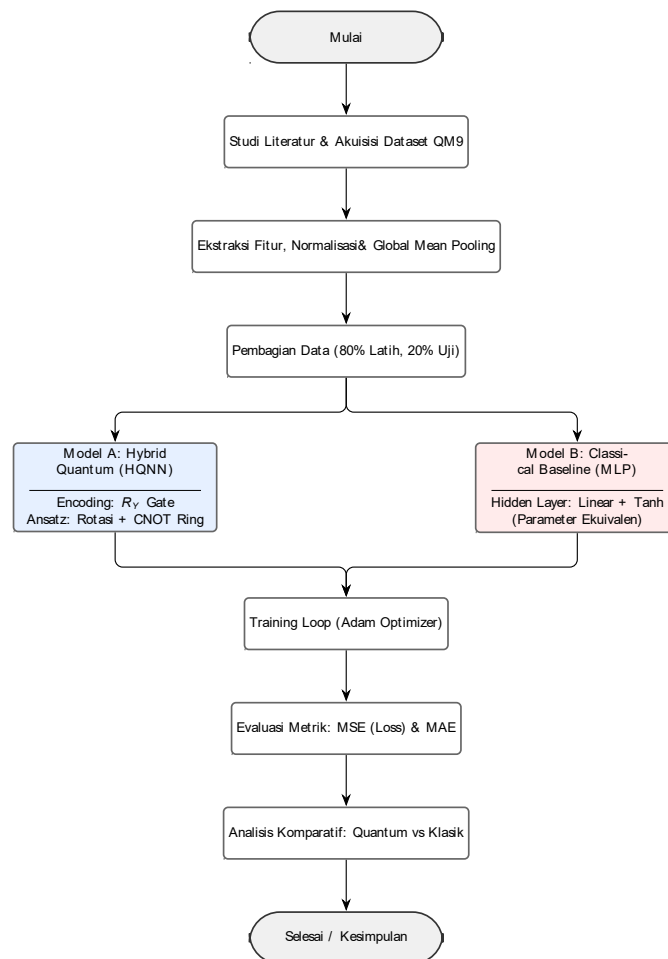
Penelitian ini mengisi celah literatur dengan menerapkan konsep PQC tersebut secara spesifik untuk tugas regresi pada dataset QM9, membandingkan efisiensi parameternya secara langsung dengan model klasik.

METODE PENELITIAN

Penelitian ini menerapkan pendekatan eksperimental komparatif untuk mengevaluasi efisiensi parameter arsitektur *Hybrid Quantum-Classical Neural Network* (HQNN) :

1. Pra-pemrosesan data, dataset QM9 diproses melalui ekstraksi fitur atom dan normalisasi target energi (U_0). Teknik *Global Mean Pooling* diterapkan untuk mentransformasi struktur graf molekul menjadi representasi vektor fitur yang invarian terhadap jumlah atom. Data kemudian dipartisi menjadi 80% himpunan latih dan 20% himpunan uji.
2. Desain arsitektur dibangun dengan kompleksitas parameter yang ekuivalen (~ 70 parameter) untuk memastikan perbandingan yang adil (*fair comparison*):
 - o Model A (HQNN) : Menggunakan sirkuit variasional dengan *encoding* rotasi R_Y


- dan *Ansatz* bertopologi cincin (*entangler layers*) untuk menangkap korelasi fitur di ruang Hilbert.
- Model B (*Classical MLP*) : Menggunakan arsitektur *Multi-Layer Perceptron* dengan lapisan linear dan fungsi aktivasi Tanh sebagai *baseline* klasik.
3. Pelatihan model, dengan optimasi parameter dilakukan menggunakan algoritma Adam untuk meminimalkan fungsi kerugian *Mean Squared Error* (MSE) hingga model mencapai konvergensi.
 4. Evaluasi kinerja dengan validasi akhir dilakukan menggunakan metrik *Mean Absolute Error* (MAE) untuk mengukur deviasi rata-rata prediksi model terhadap nilai *ground truth*.



Gambar 1. Diagram Alur Metodologi Penelitian

Model ini mengintegrasikan lapisan klasik untuk *embedding* awal dengan sirkuit variational quantum (*Variational Quantum Circuit*). Arsitektur sirkuit ditunjukkan pada Gambar 2.

Quantum Variational Circuit Architecture



Gambar 2. Arsitektur Sirkuit Variasional Quantum dengan Encoding R_Y dan Entanglement CNOT

Spesifikasi sirkuit quantum yang dirancang dalam penelitian ini menggunakan sistem 4 qubit sebagai basis komputasi. Proses dimulai dengan pengkodean data klasik ke dalam status quantum melalui teknik *Angle Embedding* yang memanfaatkan gerbang rotasi R_Y . Selanjutnya, pada lapisan variasional (*ansatz*), diterapkan kombinasi gerbang rotasi parameter untuk menangani fitur individu serta gerbang CNOT dengan konfigurasi topologi cincin (*Ring Topology*) yang berfungsi menciptakan *entanglement* antar-qubit. Sebagai tahap akhir, output model diperoleh melalui pengukuran nilai ekspektasi pada basis Pauli-Z.

HASIL DAN PEMBAHASAN

Verifikasi Representasi Data dan Target Energi

Sebelum masuk ke tahap pelatihan, dilakukan inspeksi terhadap sampel data untuk memverifikasi kesesuaian antara input (fitur atom) dan output target (Energi Internal U_0). Verifikasi ini penting untuk memastikan bahwa proses *preprocessing* tidak merusak integritas informasi kimiawi.

Tabel berikut menampilkan sampel data dari *log* sistem yang menunjukkan tensor fitur atom setelah normalisasi beserta nilai energi internal U_0 aktual yang menjadi target prediksi.

Tabel 1. Sampel Data Input dan Target Energi (U_0)

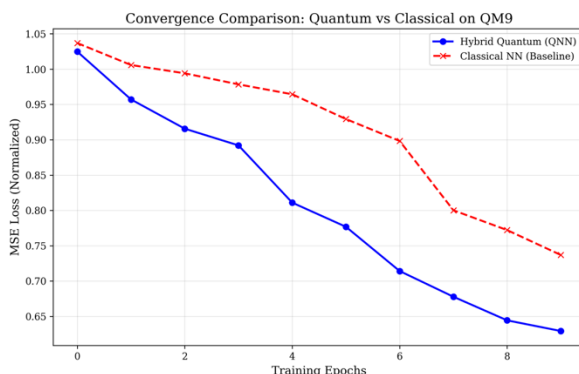
ID Sampel	Struktur Molekul (Input)	Representasi Tensor (Disederhanakan)	Target Energi U_0 (Hartree)
Molekul 1	-H-H-H-H	[[0, 1, 0, ..., 4], ...]	-1101.4878
Molekul 2	-H-H-H	[[0, 0, 1, ..., 3], ...]	-1538.1477

Tabel 1 menampilkan dua sampel data dari dataset QM9. Kolom struktur molekul menunjukkan estimasi ikatan hidrogen, sementara kolom representasi tensor memperlihatkan bagaimana fitur tersebut dikodekan menjadi matriks angka (seperti terlihat pada nilai 0, 1, 0...) yang siap diproses oleh sirkuit quantum. Nilai target energi U_0 untuk kedua sampel tersebut berada pada kisaran -1100 hingga -1500 *Hartree*, yang menjadi acuan *Ground Truth* bagi model untuk melakukan prediksi.

Analisis Konvergensi Pelatihan

Proses pelatihan (*training*) dilakukan selama 20 *epoch* menggunakan pengoptimal

Adam dengan laju pembelajaran (*learning rate*) 0.01. Evaluasi proses pembelajaran dipantau melalui grafik penurunan fungsi kerugian (*Loss Function*) berbasis *Mean Squared Error* (MSE), sebagaimana ditunjukkan pada Gambar 3.



Gambar 3. Grafik Perbandingan Penurunan Loss Hybrid Quantum vs Classical MLP

Berdasarkan hasil eksperimen, terlihat perbedaan karakteristik konvergensi antara kedua model:

1. Model klasik (MLP *baseline*) menunjukkan penurunan *loss* yang stabil namun cenderung mengalami stagnasi (*plateau*) lebih awal. Pada akhir pelatihan, model klasik berhenti pada nilai MSE sebesar 0.7369. Hal ini mengindikasikan indikasi *underfitting* pada jumlah parameter yang terbatas (~70 parameter).
2. Model *Hybrid Quantum* (HQNN) menunjukkan kemampuan optimasi yang lebih baik dengan mencapai titik minimum yang lebih rendah, yaitu MSE sebesar 0.6292. Kurva konvergensi model quantum terlihat lebih tajam di awal, menandakan efisiensi pencarian gradien dalam ruang parameter yang kompleks.

Komparasi Kinerja pada Data Uji

Untuk mengukur kemampuan generalisasi model, evaluasi dilakukan pada 20% data uji. Metrik utama yang digunakan adalah *Mean Absolute Error* (MAE). Ringkasan hasil pengujian disajikan pada tabel berikut.

Tabel 2. Hasil Evaluasi Kinerja Model

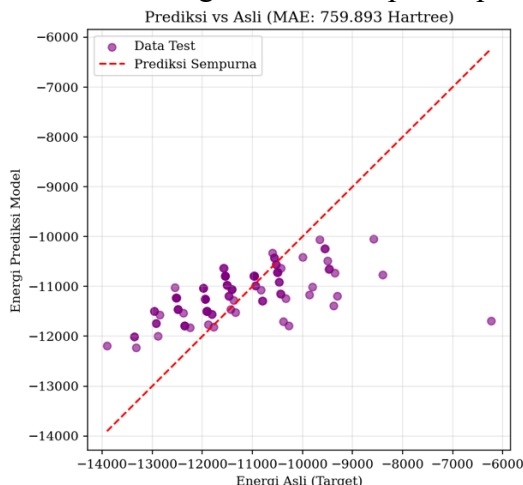
Model Arsitektur	Parameter	Training Loss (MSE)	Akurasi Error (MAE)
Model B (Classical MLP)	72	0.7369	~785.0000 Ha
Model A (Hybrid Quantum)	72	0.6292	759.8927 Ha

Tabel 2 menyajikan evaluasi kuantitatif antara model *Hybrid Quantum* (Model A) dan *Classical Baseline* (Model B) yang, meskipun keduanya dibatasi secara ketat dengan jumlah parameter identik sebanyak 72, menunjukkan perbedaan performa yang signifikan. Terkait efisiensi konvergensi, model Quantum mencatatkan nilai MSE akhir sebesar 0.6292, lebih rendah dibandingkan model Klasik yang berhenti di angka 0.7369; selisih ini membuktikan bahwa sirkuit quantum memiliki daya ekspresi (*expressibility*) yang lebih tinggi untuk memetakan fitur atom ke target energi meskipun dengan jumlah parameter yang terbatas. Selanjutnya, dari segi akurasi prediksi riil, model Quantum mencatatkan rata-rata kesalahan (*MAE*) sebesar 759.89 Hartree, mengungguli model Klasik. Keunggulan ini diatribusikan pada fitur *Quantum Entanglement* melalui gerbang CNOT yang menciptakan korelasi non-lokal untuk menangkap interaksi kimiawi rumit, berbeda

dengan model Klasik yang memproses hubungan antar fitur secara linear dan terpisah. Secara keseluruhan, hasil ini mengonfirmasi bahwa pendekatan *Hybrid Quantum* menawarkan solusi yang lebih efisien secara parameter (*parameter efficient*) dibandingkan pendekatan *Deep Learning* konvensional untuk dataset molekuler.

Analisis Distribusi Prediksi

Kualitas prediksi dianalisis lebih lanjut melalui visualisasi scatter plot yang memetakan hubungan antara nilai prediksi model (Y_{pred}) pada sumbu vertikal dan nilai actual (Y_{true}) pada sumbu horizontal, sebagaimana ditampilkan pada gambar berikut.



Gambar 4. Scatter Plot Prediksi Energi vs Nilai Aktual (Ground Truth)

Visualisasi pada Gambar 4 memperlihatkan distribusi data uji (titik ungu) yang cenderung mengikuti pola linier di sepanjang garis diagonal referensi (garis putus-putus merah). Kedekatan titik-titik data terhadap garis diagonal ini mengindikasikan bahwa model quantum berhasil menangkap korelasi umum dari properti energi molekuler.

Meskipun demikian, terlihat adanya variansi atau *noise* di mana beberapa titik prediksi melebar dari garis ideal. Hal ini merupakan fenomena yang wajar mengingat arsitektur ini beroperasi di bawah batasan *Noisy Intermediate-Scale Quantum* (NISQ) dengan hanya menggunakan 4 *qubit* dan ~ 72 parameter, kapasitas yang jauh lebih kecil dibandingkan model *Deep Learning* klasik yang biasanya melibatkan ribuan parameter untuk mencapai presisi yang lebih tinggi. Namun, tren positif yang terbentuk menegaskan bahwa fitur *entanglement* pada sirkuit telah berfungsi dalam mengenali pola data kimia.

Pembahasan

Temuan utama dalam penelitian ini menyoroti superioritas efisiensi parameter dari arsitektur *Hybrid Quantum Neural Network* (HQNN) dibandingkan *Classical Multi-Layer Perceptron* (MLP) pada rezim data molekuler dengan batasan komputasi yang ketat. Evaluasi empiris menunjukkan bahwa model quantum mencapai konvergensi pelatihan yang lebih baik dengan nilai MSE 0.6292, mengungguli model klasik yang berhenti di angka 0.7369 pada jumlah parameter yang ekuivalen (≈ 72). Fenomena ini mengonfirmasi hipotesis teoretis mengenai tingginya daya ekspresi (*expressibility*) sirkuit quantum; berbeda dengan jaringan saraf klasik yang mengalami penyempitan informasi (*information bottleneck*) akibat terbatasnya dimensi matriks bobot, sirkuit quantum memproses informasi melalui operasi uniter di ruang Hilbert berdimensi eksponensial. Kapasitas ini memungkinkan model untuk menavigasi sub-ruang solusi yang jauh lebih kaya untuk memetakan fitur molekuler yang kompleks, meskipun hanya dikendalikan oleh sejumlah kecil parameter rotasi.

Keunggulan akurasi prediksi model quantum, yang mencatatkan MAE sebesar 759.89 Hartree, dapat diatribusikan secara spesifik pada peran krusial *quantum entanglement* yang dihasilkan oleh gerbang CNOT dalam topologi cincin sirkuit. Dalam konteks kimia quantum, energi molekuler sangat ditentukan oleh korelasi elektron yang bersifat non-lokal. Struktur sirkuit yang saling terbelit (*entangled*) memberikan bias induktif yang alami untuk memodelkan sistem ini, di mana interaksi antar-qubit bertindak sebagai analogi komputasi yang efektif terhadap interaksi fisik antar-atom. Hal ini kontras dengan model MLP klasik yang memproses fitur secara independen pada lapisan awal, sehingga sering kali gagal menangkap korelasi halus antar-atom tanpa dukungan arsitektur yang sangat dalam (*deep architecture*).

Meskipun visualisasi *scatter plot* masih menunjukkan adanya *noise* yang merefleksikan batasan perangkat *Noisy Intermediate-Scale Quantum* (NISQ) dengan resolusi 4 qubit, stabilitas kurva penurunan *loss* mengindikasikan bahwa lanskap optimasi sirkuit ini relatif terhindar dari fenomena *Barren Plateaus*. Hal ini menegaskan bahwa untuk aplikasi skala kecil hingga menengah, pendekatan hibrida quantum menawarkan keuntungan komputasi yang nyata dalam hal efisiensi representasi data dibandingkan jaringan saraf klasik konvensional.

KESIMPULAN

Penelitian ini menyimpulkan bahwa arsitektur *Hybrid Quantum Neural Network* (HQNN) menunjukkan efisiensi parameter yang superior dibandingkan *Classical Multi-Layer Perceptron* (MLP) dalam memprediksi energi internal molekul U_0 pada dataset QM9. Pada kondisi jumlah parameter yang dibatasi secara ketat (≈ 72), model quantum terbukti mencapai stabilitas konvergensi yang lebih baik dengan nilai MSE 0.6292 dibandingkan model klasik (0.7369), serta mencatatkan akurasi prediksi yang lebih presisi dengan MAE 759.89 Hartree. Superioritas ini divalidasi oleh mekanisme *quantum entanglement* dalam sirkuit yang memberikan bias induktif alami untuk menangkap interaksi non-lokal antar-atom, melampaui kapasitas representasi linear model klasik. Hasil ini mengukuhkan potensi algoritma quantum variasional sebagai pendekatan yang efisien secara komputasi untuk simulasi kimia di era *Noisy Intermediate-Scale Quantum* (NISQ).

REFERENSI

- Avramouli, M., Savvas, I. K., Vasilaki, A., & Garani, G. (2023). Unlocking the potential of quantum machine learning to advance drug discovery. *Electronics*, 12(11), 2402.
- Bai, S.-C., & Ran, S.-J. (2025). Machine Learning of Chaotic Characteristics in Classical Nonlinear Dynamics Using Variational Quantum Circuit. *Chinese Physics B*.
- Cerezo, M., Arrasmith, A., Babbush, R., Benjamin, S. C., Endo, S., Fujii, K., McClean, J. R., Mitarai, K., Yuan, X., & Cincio, L. (2021). Variational quantum algorithms. *Nature Reviews Physics*, 3(9), 625–644.
- Dawson, W., Degomme, A., Stella, M., Nakajima, T., Ratcliff, L. E., & Genovese, L. (2022). Density functional theory calculations of large systems: Interplay between fragments, observables, and computational complexity. *Wiley Interdisciplinary Reviews: Computational Molecular Science*, 12(3), e1574.
- Gangwal, A., & Lavecchia, A. (2025). Artificial intelligence in natural product drug discovery: current applications and future perspectives. *Journal of medicinal chemistry*, 68(4), 3948–3969.
- Hakim, D. F., Prayitno, T. B., & Sarwono, Y. P. (2024). Application of Variational Quantum Eigensolver for Ground State Energies Calculation in Hydrogen and Helium Atomic Sequences. *interactions*, 10, 12.

- Hubregtsen, T., Pichlmeier, J., Stecher, P., & Bertels, K. (2021). Evaluation of parameterized quantum circuits: on the relation between classification accuracy, expressibility, and entangling capability. *Quantum Machine Intelligence*, 3(1), 9.
- Karthikeyan, A., & Priyakumar, U. D. (2022). Artificial intelligence: machine learning for chemical sciences. *Journal of Chemical Sciences*, 134(1), 2.
- Karuppasamy, K., Puram, V., Johnson, S., & Thomas, J. P. (2025). A comprehensive review of quantum circuit optimization: Current trends and future directions. *Quantum Reports*, 7(1), 2.
- Kübler, J., Buchholz, S., & Schölkopf, B. (2021). The inductive bias of quantum kernels. *Advances in Neural Information Processing Systems*, 34, 12661–12673.
- Lamichhane, P., & Rawat, D. B. (2025). Quantum Machine Learning: Recent Advances, Challenges and Perspectives. *IEEE Access*.
- Liyaqat, T., Ahmad, T., & Saxena, C. (2025). Advancements in Molecular Property Prediction: A Survey of Single and Multimodal Approaches: T. Liyaqat et al. *Archives of Computational Methods in Engineering*, 1–31.
- Macaluso, A. (2024). Quantum Supervised Learning. *KI - Künstliche Intelligenz*, 38(4), 277–291. <https://doi.org/10.1007/s13218-024-00856-7>
- Mihaylov, D. I., Karasiev, V. V., Hu, S. X., Rygg, J. R., Goncharov, V. N., & Collins, G. W. (2021). Improved first-principles equation-of-state table of deuterium for high-energy-density applications. *Physical Review B*, 104(14), 144104.
- Niazi, S. K., & Mariam, Z. (2023). Recent advances in machine-learning-based chemoinformatics: a comprehensive review. *International Journal of Molecular Sciences*, 24(14), 11488.
- Ramakrishnan, R., Dral, P. O., Rupp, M., & von Lilienfeld, O. A. (2014). Quantum chemistry structures and properties of 134 kilo molecules. *Scientific Data*, 1(1), 140022. <https://doi.org/10.1038/sdata.2014.22>
- Rietsche, R., Dremel, C., Bosch, S., Steinacker, L., Meckel, M., & Leimeister, J.-M. (2022). Quantum computing. *Electronic Markets*, 32(4), 2525–2536.
- Ruddigkeit, L., van Deursen, R., Blum, L. C., & Reymond, J.-L. (2012). Enumeration of 166 Billion Organic Small Molecules in the Chemical Universe Database GDB-17. *Journal of Chemical Information and Modeling*, 52(11), 2864–2875. <https://doi.org/10.1021/ci300415d>
- Tacchino, F., Mangini, S., Barkoutsos, P. K., Macchiavello, C., Gerace, D., Tavernelli, I., & Bajoni, D. (2021). Variational learning for quantum artificial neural networks. *IEEE Transactions on Quantum Engineering*, 2, 1–10.
- Tang, M., Li, B., & Chen, H. (2023). Application of message passing neural networks for molecular property prediction. *Current Opinion in Structural Biology*, 81, 102616.
- Tychola, K. A., Kalampokas, T., & Papakostas, G. A. (2023). Quantum machine learning—an overview. *Electronics*, 12(11), 2379.
- Yu, Z., Chen, Q., Jiao, Y., Li, Y., Lu, X., Wang, X., & Yang, J. (2024). Non-asymptotic approximation error bounds of parameterized quantum circuits. *Advances in Neural Information Processing Systems*, 37, 99089–99127.