

KOMPARASI *ADAPTIVE MOMENT ESTIMATION (ADAM), ANALYTIC QUANTUM GRADIENT DESCENT (AQGD) DAN NAKANISHI-FUJII-TODO (NFT)* PADA *QUANTUM PERCEPTRON*

Lipantri Mashur Gultom¹⁾, Desi Amirullah²⁾

^{1,2}Teknik Informatika, Politeknik Negeri Bengkalis, Jl. Bathin Alam, Sungai Alam, Bengkalis, Riau, 28711
E-mail: lipantri@polbeng.ac.id

Abstract

This study discusses the comparison between Adaptive Moment Estimation (ADAM), Analytic Quantum Gradient Descent (AQGD) and Nakanishi-Fujii-Todo (NFT) on Quantum Perceptron. Experiments using Qiskit and IBM Quantum Lab and UCI Machine Learning Dataset. Where every 4 datasets used are divided into learning (75%) and testing (25%). The experimental results of the 4 datasets used by the AQGD method were the best in finding values, respectively 2.1509646, 0.720, 0.3800922 and 0.4906909. While the learning accuracy values for 3 datasets using the AGQD method were the best with values of 0.500, 0.720 and 0.600, respectively. However, the test value has not yet obtained the best results from the three methods, still relying on the data structure used.

Keywords: ADAM, AQGD, NFT, Quantum, Perceptron

Abstrak

Penelitian ini membahas komparasi antara *Adaptive Moment Estimation (ADAM)*, *Analytic Quantum Gradient Descent (AQGD)* Dan *Nakanishi-Fujii-Todo (NFT)* Pada *Quantum Perceptron*. Ekperimen menggunakan *Qiskit* dan *IBM Quantum Lab* serta *UCI Machine Learning Dataset*. Dimana dari setiap 4 dataset yang digunakan dibagi menjadi bagian pembelajaran (75%) dan pengujian (25%). Hasil eksperimen dari 4 dataset yang digunakan metode AQGD menjadi terbaik dalam mencari nilai cost secara berturut-turut 2.1509646, 0.720, 0.3800922 dan 0.4906909. Sedangkan nilai akurasi pembelajaran untuk 3 dataset dengan metode AGQD menjadi yang terbaik dengan nilai secara berturut-turut 0.500, 0.720 dan 0.600. Namun untuk nilai akurasi pengujian masih belum diperoleh hasil yang terbaik dari ketiga metode tersebut karena masih kompetitif bergantung dari struktur data yang digunakan.

Kata Kunci: ADAM, AQGD, NFT, Quantum, Perceptron

PENDAHULUAN

Quantum perceptron merupakan salah satu bentuk dari jaringan saraf tiruan yang mengadopsi konsep komputasi kuantum. Di dalam komputasi kuantum di kenal beberapa istilah seperti *quantum bit* (Qubit), *superposition*, *entanglement*, *quantum logic* dan *quantum circuit*. Beberapa istilah tersebut pada dasarnya sangat penting dalam pengembangan algoritma-algoritma pembelajaran yang lebih baik pada bidang *quantum machine learning*. Namun karena teknologi komputasi kuantum sekarang ini yang masih

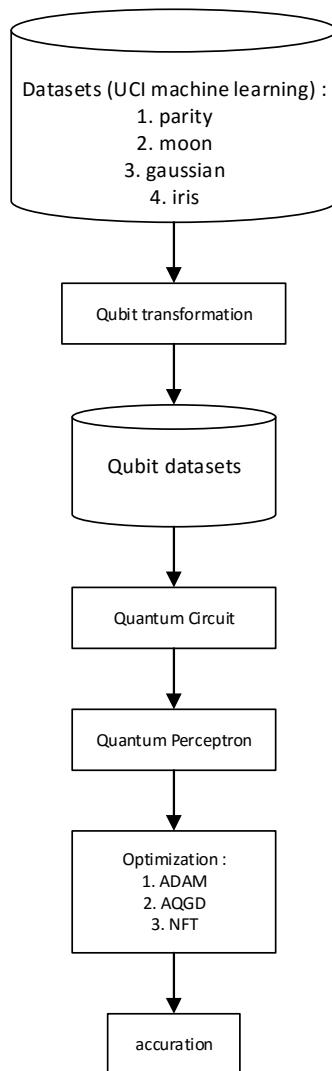
dalam tahap pengembangan baik *hardware* maupun *software* maka pada penelitian ini masih difokuskan pada metode dan algoritma yang berhubungan dengan komputasi kuantum khususnya *quantum perceptron* (Wahyudi et al., 2020).

Pada dasarnya *quantum perceptron* memiliki konsep yang sama dengan *perceptron* pada jaringan saraf tiruan yang biasanya digunakan untuk pengklasifikasian data dengan metode *supervised learning* (Gultom, 2017). Hasil beberapa studi intensif pada *quantum perceptron* terdapat beberapa kelebihan dan kekurangan dalam pengklasifikasian data (Amirullah & Gultom, 2019). Beberapa kelebihannya seperti kecepatan pembelajaran yang lebih baik dibandingkan dengan *perceptron* klasik sedangkan kekurangannya yaitu sulit menemukan tingkat akurasi yang optimal dalam pengklasifikasian data (Mangini et al., 2021). Kekurangan ini dipengaruhi oleh beberapa faktor salah satunya seperti model *quantum circuit* yang menjadi arsitektur jaringan saraf tiruan yang digunakan saat ini masih belum menemukan arsitektur yang optimal (Macaluso et al., 2020).

Dari beberapa studi saat ini terdapat beberapa metode optimasi yang paling baik yang digunakan dalam tahapan *pre-processing/transformation* yang biasanya digunakan dalam pengolahan data pada bidang *quantum machine learning*. Beberapa metode yang dikenal saat ini yaitu *Quantum Perceptron Dengan Adaptive Moment Estimation* (ADAM) (Kingma & Ba, 2014; Reddi et al., 2019), *Analytic Quantum Gradient Descent* (AQGD) (Mitarai et al., 2018; Schuld et al., 2019) Dan *Nakanishi-Fujii-Todo* (NFT) (Nakanishi et al., 2020). Hasil studi dari beberapa metode ini sangat cocok dan baik jika diterapkan pada *quantum perceptron* yang menggunakan *quantum circuit* sebagai arsitekturnya. Namun dari beberapa studi tersebut juga masih terdapat kelebihan dan kekurangan pada setiap metode tersebut dalam menemukan nilai akurasi yang optimal. Karena pada dasarnya nilai akurasi sangat penting pada kinerja satu mesin dalam pengklasifikasian data. Oleh karena itu penelitian ini difokuskan untuk menemukan nilai akurasi yang optimal dari beberapa metode yang sudah dipaparkan diatas.

METODE PENELITIAN

Dalam penelitian ini menggunakan beberapa tahapan berikut ini.

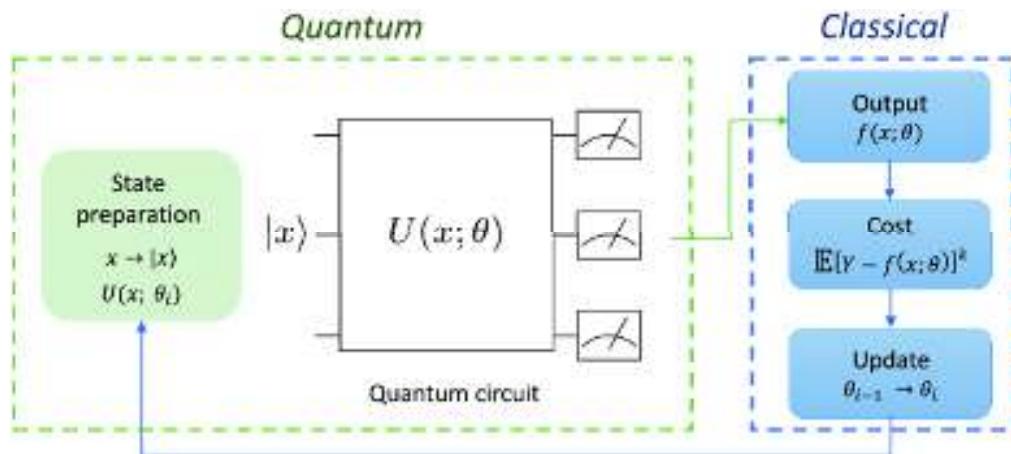


Gbr. 1 Metode Penelitian

Dari beberapa tahapan tersebut dataset yang digunakan bersumber dari *UCI Machine learning* repository yang terdiri dari 4 dataset dimana setiap dataset akan dibagi menjadi dua bagian yaitu untuk proses pelatihan (75%) dan proses pengujian (25%). Kemudian setiap dataset tersebut ditransformasikan kedalam *qubit* dengan *amplitude encoding*

$$|x\rangle = \sum_{k=1}^d s_k |k\rangle \longleftrightarrow x = \begin{pmatrix} s_1 \\ \vdots \\ s_d \end{pmatrix}$$

Dimana $|x\rangle$ merupakan amplitudo dari *quantum state*.



Gbr. 2 Skema algoritma hybrid quantum-classical untuk supervised learning.

Rangkaian variasi kuantum digambarkan dengan warna hijau, sedangkan komponen klasik diwakili dengan warna biru (Macaluso et al., 2020).

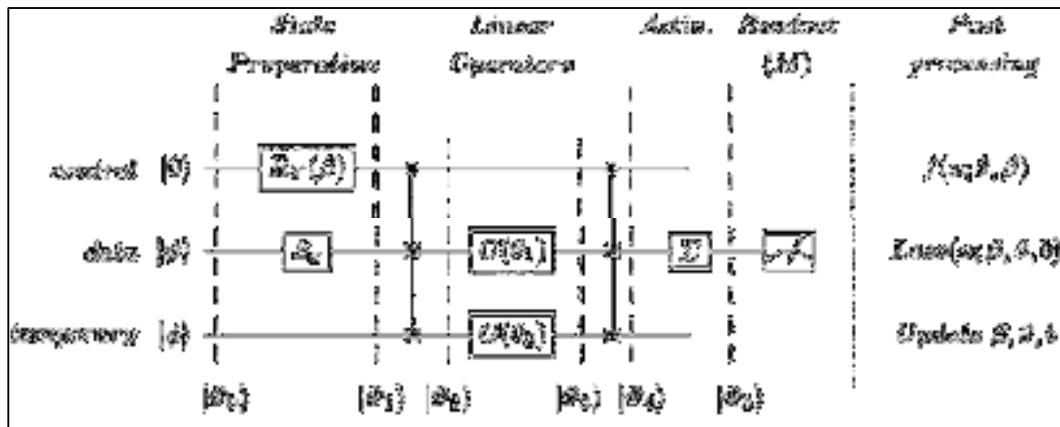
Kemudian dilakukan perancangan *quantum circuit* sebagai arsitektur *neural network* dengan mengadopsi *Quantum Single Layer Perceptron*.

$$U(\theta) = U_{L_1} \cdots U_L \cdots U_{L_1}$$

Dimana $U(\theta)$ merupakan serangkaian gerbang *quantum* yang memiliki nilai U_1 terdiri dari *single-qubit*. Agar *single-qubit* dapat dilakukan proses pembelajaran maka nilai U_1 harus ditransformasi kedalam matrik 2×2 dengan rumus

$$U(\theta, \beta, \gamma) = \begin{pmatrix} e^{i\theta \cos(\alpha/2)} & e^{i\beta \sin(\alpha/2)} \\ e^{-i\gamma \sin(\alpha/2)} & e^{-i\beta \cos(\alpha/2)} \end{pmatrix}$$

Algoritma pembelajarannya terdiri dari *state preparation*, *entangled linear operators in superposition*, *application of the activation function*, *read-out step*, *post-processing* dengan rancangan arsitektur sebagai berikut.

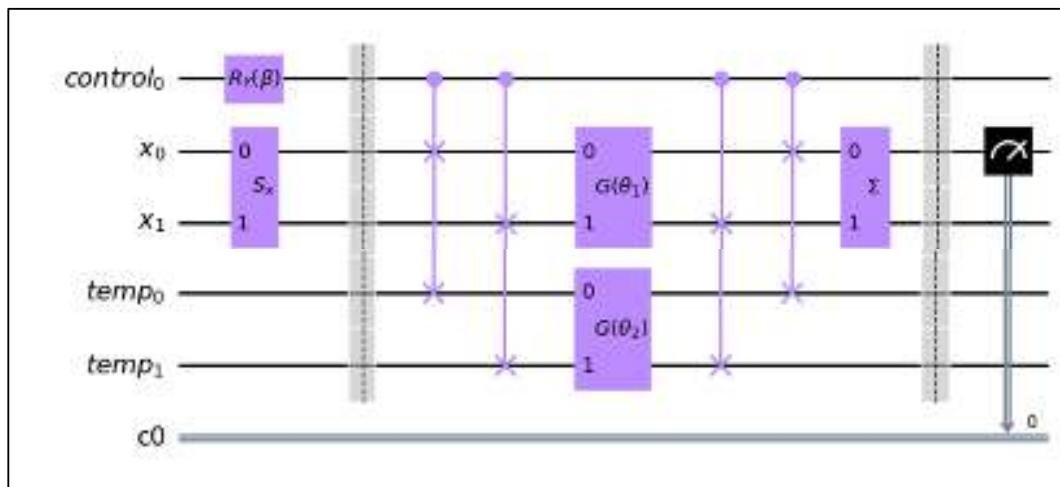
Gbr. 3 Rancangan *Quantum Single Layer Perceptron*

Sedangkan untuk *Adaptive Moment Estimation* (ADAM), *Analytic Quantum Gradient Descent* (AQGD) Dan *Nakanishi-Fujii-Todo* (NFT) digunakan untuk pengoptimalan.

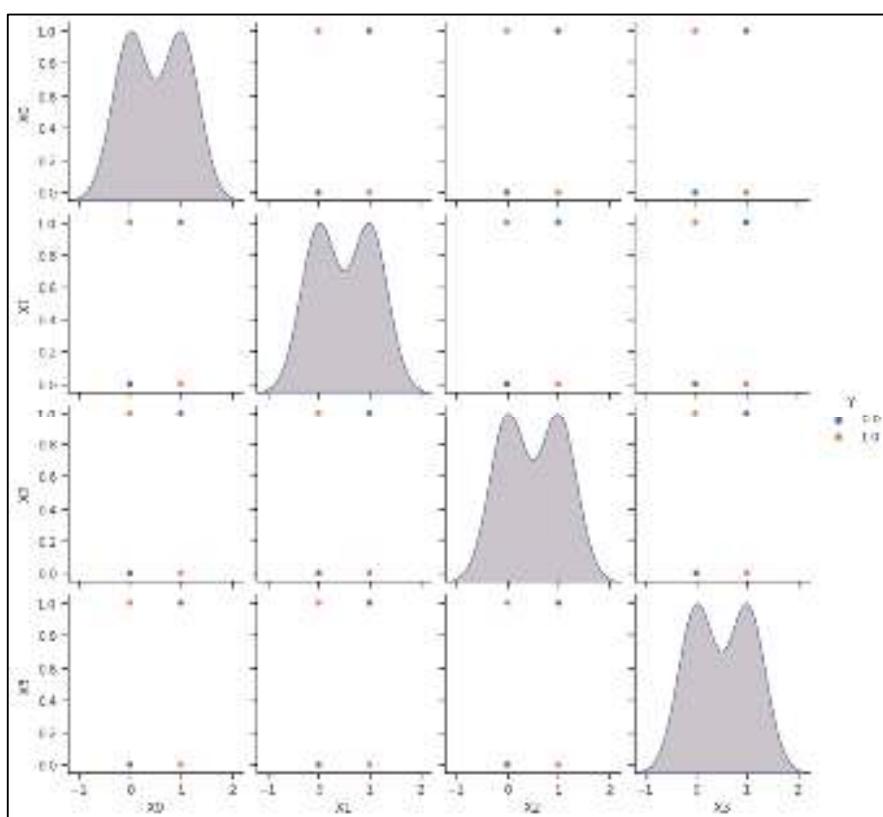
HASIL DAN PEMBAHASAN

Seluruh proses pada penelitian ini menggunakan Qiskit dalam IBM Quantum Lab dengan hasil sebagai berikut ini

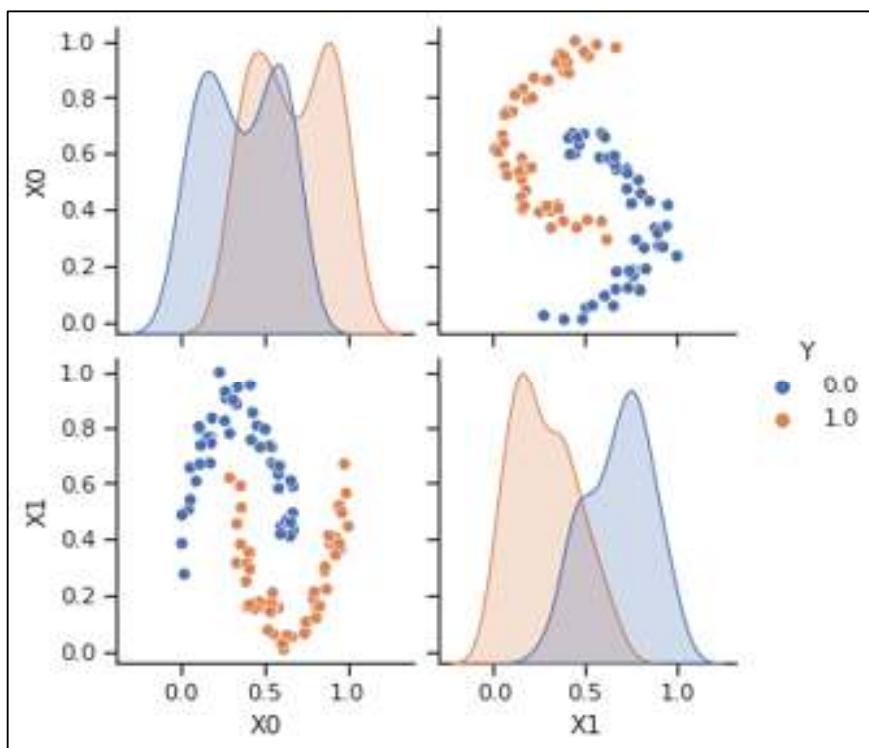
A. Arsitektur *Quantum Perceptron*

Gbr. 4 Implementasi *Quantum Single Layer Perceptron* dengan Qiskit

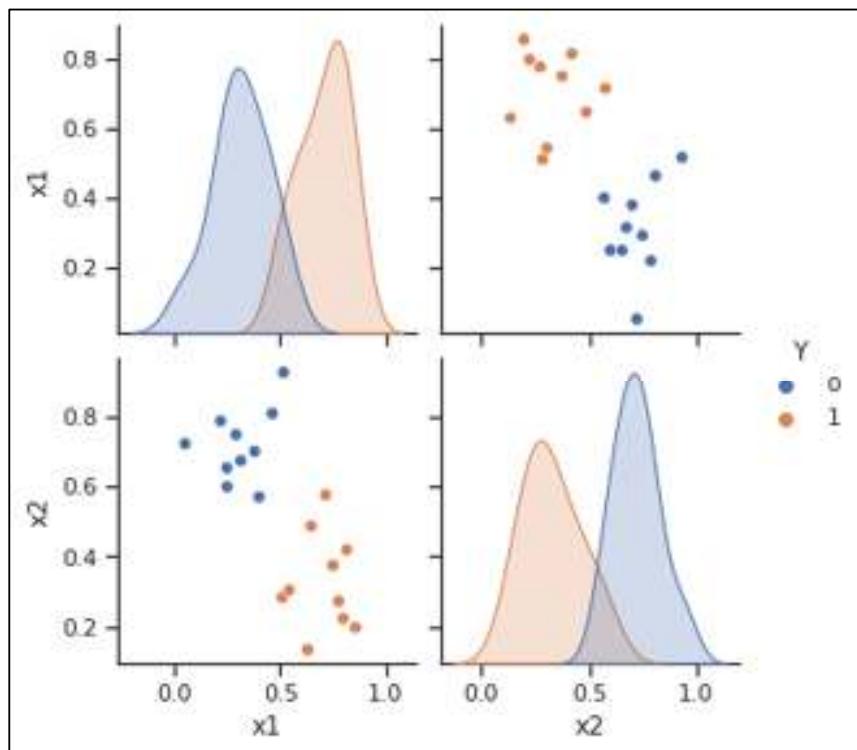
B. Plot distribusi beberapa dataset menjadi dua kelas



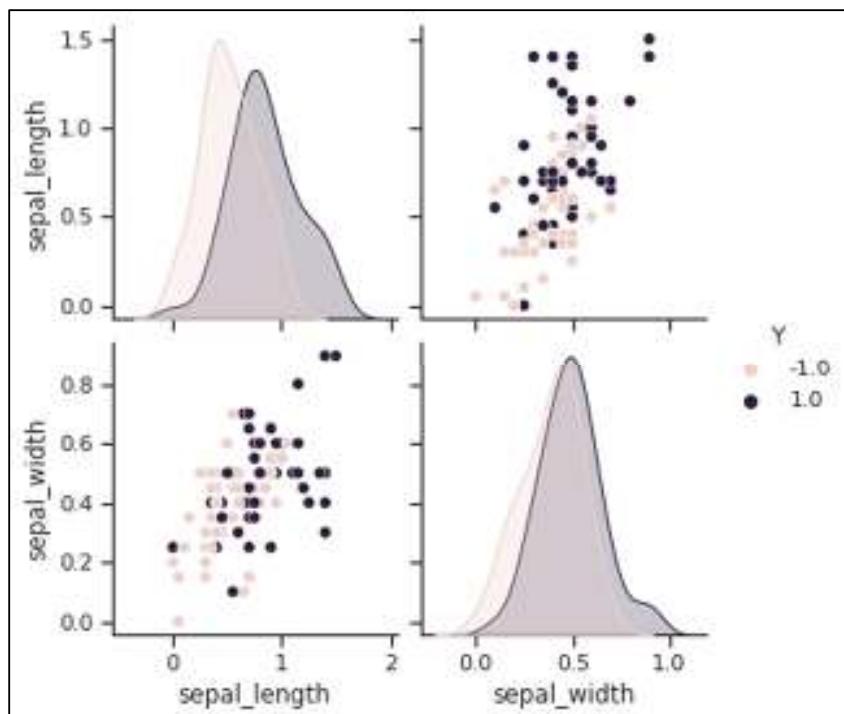
Gbr. 4 Distribusi dataset parity kedalam dua kelas 0 dan 1



Gbr. 5 Distribusi dataset moon kedalam dua kelas 0 dan 1



Gbr. 6 Distribusi dataset gaussian kedalam dua kelas 0 dan 1



Gbr. 7 Distribusi dataset gaussian kedalam dua kelas -1 dan 1

C. Hasil beberapa perbandingan optimalisasi Adaptive Moment Estimation (ADAM), Analytic Quantum Gradient Descent (AQGD) dan Nakanishi-Fujii-Todo (NFT)

Tabel 1

Hasil Cost, Akurasi Pembelajaran Dan Akurasi Pengujian

No	Dataset	ADAM	AQGD	NFT
1	Parity	Cost: 4.2509200	Cost: 2.1509646	Cost: 3.1079452
		Acc train: 0.417	Acc train: 0.500	Acc train: 0.417
		Acc validation: 0.500	Acc validation: 0.250	Acc validation: 0.500
2	Moon	Cost: 0.4127257	Cost: 0.3589749	Cost: 0.3924047
		Acc train: 0.627	Acc train: 0.720	Acc train: 0.667
		Acc validation: 0.720	Acc validation: 0.520	Acc validation: 0.720
3	Gaussian	Cost: 0.3880140	Cost: 0.3800922	Cost: 0.3908771
		Acc train: 0.400	Acc train: 0.600	Acc train: 0.533
		Acc validation: 0.400	Acc validation: 0.400	Acc validation: 0.400
4	Iris	Cost: 0.5314191	Cost: 0.4906909	Cost: 0.5474630
		Acc train: 0.387	Acc train: 0.320	Acc train: 0.293
		Acc validation: 0.120	Acc validation: 0.240	Acc validation: 0.440

Dari tabel tersebut dapat diuraikan sebagai berikut :

- 1) Untuk dataset parity nilai cost terbaik pada metode AQGD yaitu 2.1509646 sedangkan untuk nilai acc train terbaik pada metode AQGD yaitu 0.500 dan nilai Acc validation terbaik pada metode ADAM dan AQGD yaitu 0.500
- 2) Untuk dataset moon nilai cost terbaik pada metode AQGD yaitu 0.720 sedangkan untuk nilai acc train terbaik pada metode AQGD yaitu 0.720 dan nilai Acc validation terbaik pada metode ADAM dan AQGD yaitu 0.720
- 3) Untuk dataset gaussian nilai cost terbaik pada metode AQGD yaitu 0.3800922 sedangkan untuk nilai acc train terbaik pada metode AQGD yaitu 0.600 dan nilai Acc validation ADAM, AQGD dan NFT memiliki nilai yang sama yaitu 0.400

Untuk dataset iris nilai cost terbaik pada metode AQGD yaitu 0.4906909 sedangkan untuk nilai acc train terbaik pada metode ADAM yaitu 0.387 dan nilai Acc validation terbaik pada metode NFT yaitu 0.440.

SIMPULAN

Dari hasil akhir penelitian ini dapat disimpulkan bahwa setiap metode optimalisasi memiliki kelebihan dan kekurang dalam mencari nilai cost, akurasi pembelajaran dan pengujian. Dimana metode AQGD lebih baik untuk mencari nilai cost pada 4 dataset sedangkan metode AQGD juga masih lebih baik untuk mencari nilai akurasi pelatihan

dari 3 dataset sedangkan ADAM hanya pada satu dataset saja. Kemudian untuk nilai akurasi pengujian masih kompetitif karena bergantung pada struktur datasetnya.

DAFTAR PUSTAKA

- Amirullah, D., & Gultom, L. M. (2019). Data Classification with Qubit Superposition Approach in Quantum Perceptron. *2019 2nd International Conference on Applied Engineering (ICAЕ)*, 1–4.
- Gultom, L. M. (2017). Klasifikasi Data Dengan Quantum Perceptron. *Jurnal Teknologi: Jurnal Teknik Dan Inovasi*, 4(1), 1–9.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *ArXiv Preprint ArXiv:1412.6980*.
- Macaluso, A., Clissa, L., Lodi, S., & Sartori, C. (2020). A Variational Algorithm for Quantum Neural Networks. *International Conference on Computational Science*, 591–604.
- Mangini, S., Tacchino, F., Gerace, D., Bajoni, D., & Macchiavello, C. (2021). Quantum computing models for artificial neural networks. *EPL (Europhysics Letters)*, 134(1), 10002.
- Mitarai, K., Negoro, M., Kitagawa, M., & Fujii, K. (2018). Quantum circuit learning. *Physical Review A*, 98(3), 32309.
- Nakanishi, K. M., Fujii, K., & Todo, S. (2020). Sequential minimal optimization for quantum-classical hybrid algorithms. *Physical Review Research*, 2(4), 43158.
- Reddi, S. J., Kale, S., & Kumar, S. (2019). On the convergence of adam and beyond. *ArXiv Preprint ArXiv:1904.09237*.
- Schuld, M., Bergholm, V., Gogolin, C., Izaac, J., & Killoran, N. (2019). Evaluating analytic gradients on quantum hardware. *Physical Review A*, 99(3), 32331.
- Wahyudi, M., Gultom, L. M., & Solikhun, S. (2020). *Implementasi Komputasi Quantum Pada Jaringan Saraf Tiruan*. Yayasan Kita Menulis.