ANALISIS PENGARUH ARSITEKTUR DAN PARAMETER PELATIHAN *ARTIFICIAL NEURAL NETWORK* (ANN) TERHADAP KINERJA REGRESI DAN KLASIFIKASI

Ganang Aji Pamungkas[1)] Mukhamad Syafaat[2)] M. Nur Alvyangga Saputro[3)] Ito Suryo Purnomo[4)] dan Febriyantoro[5)]
[1)]Kesatrian Poltekad, Jl. Raya Anggrek, Desa Pendem, Kecamatan Junrejo, Kota Batu, Jawa Timur, Kode Pos 65324.
E - mail : ganangsersan@email.com

ANALISIS PENGARUH ARSITEKTUR DAN PARAMETER PELATIHAN ARTIFICIAL NEURAL NETWORK (ANN) TERHADAP KINERJA REGRESI DAN KLASIFIKASI

Abstract: *Artificial Neural Network (ANN) is one of the computational models used in machine learning to recognize patterns and solve prediction and classification problems. This study aims to analyze the effect of hidden layer configuration, number of neurons, activation functions, and learning rate on ANN performance for regression and classification tasks. The practical experiments were conducted using the Boston Housing dataset for regression and the Iris dataset for classification through Google Colab. The experimental results show that the number of hidden layers affects model performance, but increasing the number of layers does not always produce better results. In the regression experiment, the best neuron configuration achieved an R^2 value of 0.9930 with an MAE of 0.63, while the best activation function configuration achieved an R^2 value of 0.9958 with an MAE of 0.50. The best learning rate in the regression experiment was 0.005, producing an R^2 of 0.9961 and MAE of 0.44. In the classification experiment, the best neuron configuration and several learning rate configurations achieved an accuracy of 1.0000. The final activation function experiment showed that Softmax achieved the highest accuracy of 1.0000. These results indicate that appropriate selection of ANN architecture and training parameters is important for obtaining optimal model performance.*
Keywords: Artificial Neural Network, ANN, regression, classification, activation function, learning rate
Abstrak: *Artificial Neural Network (ANN) merupakan salah satu model komputasi dalam machine learning yang digunakan untuk mengenali pola serta menyelesaikan permasalahan prediksi dan klasifikasi. Penelitian ini bertujuan untuk menganalisis pengaruh konfigurasi hidden layer, jumlah neuron, fungsi aktivasi, dan learning rate terhadap kinerja ANN pada tugas regresi dan klasifikasi. Eksperimen dilakukan menggunakan dataset Boston Housing untuk regresi dan dataset Iris untuk klasifikasi melalui Google Colab. Hasil eksperimen menunjukkan bahwa jumlah hidden layer memengaruhi kinerja model, tetapi penambahan jumlah lapisan tidak selalu menghasilkan kinerja yang lebih baik. Pada eksperimen regresi, konfigurasi neuron terbaik menghasilkan nilai R^2 sebesar 0,9930 dengan MAE sebesar 0,63, sedangkan konfigurasi fungsi aktivasi terbaik menghasilkan R^2 sebesar 0,9958 dengan MAE sebesar 0,50. Learning rate terbaik pada eksperimen regresi adalah 0,005 dengan R^2 sebesar 0,9961 dan MAE sebesar 0,44. Pada eksperimen klasifikasi, konfigurasi neuron terbaik serta beberapa konfigurasi*

learning rate mampu menghasilkan akurasi sebesar 1,0000. Pengujian fungsi aktivasi akhir menunjukkan bahwa Softmax menghasilkan akurasi tertinggi sebesar 1,0000. Hasil tersebut menunjukkan bahwa pemilihan arsitektur dan parameter pelatihan ANN yang tepat sangat penting untuk memperoleh kinerja model yang optimal.
Kata kunci: Artificial Neural Network, ANN, regresi, klasifikasi, fungsi aktivasi, learning rate.

PENDAHULUAN

Perkembangan kecerdasan buatan telah mendorong penggunaan metode machine learning dalam berbagai bidang yang membutuhkan proses pengenalan pola, prediksi, dan pengambilan keputusan berbasis data. Salah satu metode yang banyak digunakan adalah Artificial Neural Network (ANN) atau Jaringan Syaraf Tiruan (JST). ANN merupakan model komputasi yang menggunakan struktur jaringan neuron untuk mempelajari hubungan antara data masukan dan keluaran melalui proses pelatihan. Kemampuan ANN dalam mempelajari hubungan yang kompleks dan non-linear menjadikannya salah satu pendekatan yang banyak digunakan dalam berbagai permasalahan prediksi dan klasifikasi (Dubey et al., 2022)(Calvo-pardo et al., 2023)

Neural network bekerja dengan menerima sejumlah input yang kemudian diproses menggunakan bobot dan bias. Hasil proses tersebut selanjutnya diteruskan melalui fungsi aktivasi untuk menghasilkan keluaran neuron. Proses pembelajaran dilakukan dengan memperbarui bobot jaringan berdasarkan kesalahan antara keluaran prediksi dan nilai target. Struktur jaringan yang digunakan dalam proses tersebut berpengaruh terhadap kemampuan model dalam mempelajari pola dari data. (Syaharuddin, S., Fatmawati, F., & Suprajitno, 2022) menunjukkan bahwa pemilihan parameter seperti learning rate, jumlah neuron, dan jumlah hidden layer merupakan faktor penting dalam memperoleh arsitektur ANN dengan kinerja yang baik.

Secara umum, arsitektur ANN terdiri atas input layer, hidden layer, dan output layer. Input layer berfungsi menerima data masukan, hidden layer melakukan proses transformasi dan pembelajaran pola, sedangkan output layer menghasilkan keluaran akhir sesuai dengan jenis permasalahan. Struktur dan kedalaman jaringan dapat memengaruhi kemampuan model dalam melakukan pendekatan terhadap hubungan yang terdapat pada data. (Calvo-pardo et al., 2023) menunjukkan bahwa struktur

jaringan, khususnya pemilihan width dan depth, berpengaruh terhadap kemampuan pendekatan model dan dapat meningkatkan akurasi ketika arsitektur dipilih secara tepat.

Kinerja ANN tidak hanya ditentukan oleh jenis data yang digunakan, tetapi juga dipengaruhi oleh arsitektur jaringan dan parameter pelatihan. Jumlah hidden layer merupakan salah satu parameter yang dapat memengaruhi kemampuan jaringan dalam mempelajari pola. Penambahan lapisan dapat meningkatkan kapasitas jaringan dalam merepresentasikan hubungan yang lebih kompleks, tetapi jumlah lapisan yang lebih banyak tidak selalu menghasilkan kinerja yang lebih baik. (Syaharuddin, S., Fatmawati, F., & Suprajitno, 2022) melalui penelitian meta-analisis terhadap ANN backpropagation menunjukkan bahwa jumlah hidden layer, learning rate, dan jumlah neuron merupakan parameter yang perlu diperhatikan dalam menentukan arsitektur ANN (Rochmawati, N., Hidayati, H. B., Yamasari, Y., Tjahyaningtijas, H. P. A., Yustanti, W., & Prihanto, 2021).

Selain jumlah hidden layer, jumlah neuron pada setiap lapisan juga memengaruhi kapasitas representasi model. Jumlah neuron yang lebih besar dapat memberikan kemampuan yang lebih tinggi dalam mempelajari pola yang kompleks, tetapi juga meningkatkan kompleksitas jaringan dan kebutuhan komputasi. Oleh karena itu, jumlah neuron perlu disesuaikan dengan karakteristik data dan tujuan pemodelan. Penelitian (Calvo-pardo et al., 2023) juga menunjukkan bahwa pemilihan width dan depth jaringan memiliki hubungan dengan kemampuan model dalam melakukan pendekatan terhadap fungsi yang dipelajari.

Fungsi aktivasi merupakan komponen penting dalam ANN karena digunakan untuk memberikan sifat non-linear pada keluaran neuron. Beberapa fungsi aktivasi yang umum digunakan adalah ReLU, Sigmoid, Tanh, dan Softmax. ReLU banyak digunakan pada hidden layer, sedangkan Softmax umum digunakan pada output layer untuk permasalahan klasifikasi multi-kelas. (Bouraya & Belangour, 2024) melakukan kajian komparatif terhadap berbagai fungsi aktivasi dan membahas karakteristik, kelebihan, serta keterbatasan fungsi Sigmoid, Tanh, ReLU, ELU, dan Softmax dalam jaringan neural.

(Dubey et al., 2022) juga menjelaskan bahwa fungsi aktivasi memiliki karakteristik yang berbeda berdasarkan rentang keluaran, sifat monotonik, dan tingkat kehalusan. Perbedaan karakteristik tersebut dapat memengaruhi proses pembelajaran dan kinerja jaringan. Oleh karena itu, tidak terdapat satu fungsi aktivasi yang selalu

menghasilkan kinerja terbaik untuk seluruh permasalahan. Pemilihan fungsi aktivasi perlu disesuaikan dengan karakteristik data, arsitektur jaringan, dan jenis tugas yang dilakukan.

Selain arsitektur dan fungsi aktivasi, learning rate merupakan salah satu parameter penting dalam proses pelatihan ANN. Learning rate menentukan besar perubahan bobot pada setiap proses pembaruan. Nilai yang terlalu besar dapat menyebabkan proses pembelajaran tidak stabil, sedangkan nilai yang terlalu kecil dapat memperlambat proses konvergensi. (Syaharuddin, S., Fatmawati, F., & Suprajitno, 2022) menunjukkan bahwa variasi learning rate memiliki hubungan dengan kinerja ANN dan kecepatan proses pelatihan. Penelitian mengenai adaptive learning rate juga menunjukkan bahwa proses fine-tuning terhadap parameter pembelajaran menjadi bagian penting dalam memperoleh kinerja jaringan yang baik (Li et al., 2021).

Pada permasalahan regresi, ANN dapat digunakan untuk mempelajari hubungan antara sejumlah variabel masukan dengan keluaran berupa nilai kontinu. Salah satu dataset yang digunakan dalam penelitian ANN adalah Boston Housing. (Mangala et al., 2024) membandingkan ANN dengan Linear Regression, Random Forest Regressor, dan Support Vector Regression menggunakan dataset Boston Housing. Hasil penelitian menunjukkan bahwa ANN memperoleh R^2 sebesar 0,86 dan MAE sebesar 0,047, sehingga menunjukkan kemampuan ANN dalam memodelkan hubungan non-linear pada data perumahan (Ihzaniah, L. S., Setiawan, A., Wijaya, 2023).

Penelitian mengenai arsitektur jaringan juga menunjukkan bahwa pemilihan struktur jaringan dapat memberikan pengaruh terhadap kemampuan model dalam melakukan prediksi. (Calvo-pardo et al., 2023) mengembangkan pendekatan untuk menentukan arsitektur neural network berdasarkan kemampuan pendekatan jaringan dan mengujinya pada dataset Boston Housing. Hasil penelitian menunjukkan bahwa pemilihan width dan depth yang tepat dapat meningkatkan kemampuan pendekatan model dibandingkan pemilihan arsitektur secara umum.

Pada permasalahan klasifikasi, ANN dapat digunakan untuk mengelompokkan data berdasarkan karakteristik tertentu. Salah satu dataset yang sering digunakan untuk mengevaluasi metode klasifikasi adalah Iris yang terdiri atas tiga kelas bunga. Penelitian mengenai ANN pada dataset Iris menunjukkan bahwa konfigurasi jaringan, jumlah lapisan, dan metode pelatihan dapat menghasilkan

kinerja klasifikasi yang berbeda. Penelitian terbaru mengenai karakteristik hidden layer juga menggunakan dataset Iris dan membandingkan beberapa konfigurasi kedalaman jaringan. Hasilnya menunjukkan bahwa perubahan jumlah layer dapat menghasilkan perbedaan tingkat akurasi sehingga kedalaman jaringan perlu disesuaikan dengan karakteristik data (Tirumala, 2025).

Penggunaan Softmax pada output layer juga umum diterapkan pada klasifikasi multi-kelas. Penelitian mengenai implementasi jaringan neural pada dataset Iris menunjukkan penggunaan ReLU pada hidden layer dan Softmax pada output layer untuk menghasilkan probabilitas kelas. Pendekatan tersebut menunjukkan bahwa kombinasi fungsi aktivasi pada setiap bagian jaringan perlu disesuaikan dengan fungsi lapisan tersebut.

Berdasarkan penelitian-penelitian tersebut, dapat diketahui bahwa kinerja ANN dipengaruhi oleh berbagai komponen, mulai dari jumlah hidden layer, jumlah neuron, fungsi aktivasi, hingga learning rate. Namun, konfigurasi yang memberikan kinerja terbaik pada suatu dataset belum tentu menghasilkan kinerja yang sama pada dataset lainnya. Oleh karena itu, diperlukan pengujian yang membandingkan beberapa konfigurasi ANN pada jenis permasalahan yang berbeda.

Penelitian ini dilakukan untuk menganalisis pengaruh perubahan arsitektur dan parameter pelatihan ANN terhadap kinerja model pada permasalahan regresi dan klasifikasi. Parameter yang dibandingkan meliputi jumlah hidden layer, jumlah neuron, fungsi aktivasi, dan learning rate. Pada permasalahan regresi digunakan dataset Boston Housing dengan metrik evaluasi R^2 dan MAE, sedangkan pada permasalahan klasifikasi digunakan dataset Iris dengan metrik evaluasi akurasi.

Permasalahan utama yang dikaji dalam penelitian ini adalah bagaimana perubahan arsitektur dan parameter pelatihan ANN memengaruhi kinerja model pada tugas regresi dan klasifikasi. Pengujian dilakukan dengan membandingkan beberapa konfigurasi jaringan dan parameter pelatihan untuk mengetahui konfigurasi yang memberikan kinerja terbaik pada masing-masing jenis permasalahan.

Tujuan penelitian ini adalah menganalisis pengaruh jumlah hidden layer, jumlah neuron, fungsi aktivasi, dan learning rate terhadap kinerja ANN pada permasalahan regresi dan klasifikasi. Hasil penelitian diharapkan dapat memberikan gambaran empiris mengenai hubungan antara konfigurasi arsitektur, parameter pelatihan, dan kinerja ANN sehingga dapat menjadi pertimbangan dalam menentukan

konfigurasi jaringan yang sesuai dengan karakteristik permasalahan yang digunakan.

METODE PENELITIAN

2.1 Rancangan Penelitian

Penelitian dilakukan menggunakan metode eksperimen dengan mengubah beberapa parameter pada arsitektur Artificial Neural Network. Eksperimen dibagi menjadi dua bagian, yaitu eksperimen regresi dan eksperimen klasifikasi. Tahapan penelitian meliputi persiapan dataset, perancangan arsitektur ANN, perubahan parameter, proses pelatihan model, evaluasi kinerja, dan perbandingan hasil.

Pada eksperimen pertama digunakan dataset *Boston Housing* untuk menyelesaikan permasalahan regresi. Pada eksperimen kedua digunakan dataset *Iris* untuk menyelesaikan permasalahan klasifikasi.

2.2 Alat dan Bahan

Peralatan yang digunakan dalam penelitian ini terdiri atas:

1. Laptop
2. Google Colab
3. Notebook Python format *.ipynb*
4. Dataset *Boston Housing*
5. Dataset *Iris*
6. Model *Artificial Neural Network*

Dataset Boston Housing digunakan untuk melakukan prediksi nilai kontinu sehingga dievaluasi menggunakan metrik R^2 dan MAE. Dataset Iris digunakan untuk mengklasifikasikan data ke dalam tiga kelas spesies Iris sehingga evaluasi dilakukan menggunakan nilai akurasi.

2.3 Variabel Eksperimen

Parameter yang diuji dalam eksperimen meliputi:

1. Jumlah *Hidden Layer*
2. Jumlah neuron tiap *Hidden Layer*
3. Fungsi aktivasi
4. *Learning rate*

Pada eksperimen hidden layer, jumlah layer diubah menjadi 2, 3, 4, 5, dan 6. Setelah diperoleh konfigurasi yang sesuai, dilakukan pengujian jumlah neuron pada setiap hidden layer. Tahap berikutnya dilakukan perubahan fungsi aktivasi menggunakan *ReLU, Sigmoid,* dan *Tanh.* Setelah diperoleh arsitektur terbaik, dilakukan pengujian terhadap beberapa nilai learning rate.

2.4 Teknik Evaluasi

Pada tugas regresi digunakan dua metrik, yaitu R^2 dan Mean Absolute Error (MAE). Nilai R^2 digunakan untuk menunjukkan kemampuan model dalam menjelaskan variasi data, sedangkan MAE menunjukkan rata-rata kesalahan absolut hasil prediksi terhadap nilai sebenarnya.

Semakin tinggi nilai R^2 dan semakin rendah nilai MAE menunjukkan kinerja model yang semakin baik.

Pada tugas klasifikasi digunakan akurasi sebagai metrik utama. Akurasi menunjukkan persentase data yang berhasil diklasifikasikan secara benar terhadap keseluruhan data. Selain akurasi, confusion matrix dapat digunakan untuk melihat distribusi kesalahan prediksi pada setiap kelas.

HASIL PENELITIAN

3.1 Hasil Eksperimen Regresi

3.1.1 Pengaruh Jumlah Hidden Layer

Pengujian pertama dilakukan dengan mempertahankan jumlah neuron dan mengubah jumlah hidden layer.

No	Hidden Layer	R^2	MAE
1	2	0,9883	0,84
2	3	0,9893	0,80
3	4	0,9823	0,96
4	5	0,9889	0,78
5	6	0,9891	0,78

Tabel 1. Pengaruh Jumlah Hidden Layer pada Regresi.

Berdasarkan Tabel 1, konfigurasi tiga hidden layer menghasilkan R^2 sebesar 0,9893 dan MAE sebesar 0,80. Konfigurasi empat hidden layer justru menghasilkan penurunan kinerja dengan R^2 sebesar 0,9823 dan MAE sebesar 0,96. Pada lima dan enam hidden layer, kinerja kembali meningkat dan relatif stabil.

3.1.2 Pengaruh Jumlah Neuron

Pengujian selanjutnya dilakukan dengan mengubah jumlah neuron pada masing-masing hidden layer.

No	Layer 1	Layer 2	Layer 3	Layer 4	Layer 5	R^2	MAE
1	16	8	32	8	8	0,9834	0,95
2	16	5	3	8	17	0,9930	**0,63**
3	16	15	3	17	10	0,9878	0,78
4	15	15	15	15	15	0,9889	0,76
5	5	5	5	5	5	0,9896	0,74

Tabel 2. Pengaruh Konfigurasi Neuron pada Regresi.

Konfigurasi neuron 16-5-3-8-17 menghasilkan nilai R^2 tertinggi sebesar 0,9930 dan MAE terendah sebesar 0,63 dibandingkan konfigurasi neuron lainnya.

3.1.3 Pengaruh Fungsi Aktivasi

Pengujian fungsi aktivasi dilakukan menggunakan kombinasi ReLU, Sigmoid, dan Tanh.

No	Layer 1	Layer 2	Layer 3	Layer 4	Layer 5	R^2	MAE
1	ReLU	Sigm	ReLU	ReLU	Tanh	0,8798	2,34
2	ReLU	ReLU	Sigm	Sigm	Tanh	0,8954	2,20
3	ReLU	ReLU	ReLU	Sigm	Tanh	0,9105	2,08
4	ReLU	Sigm	Sigm	Sigm	Tanh	0,4423	5,84
5	ReLU	Sigm	Tanh	ReLU	ReLU	**0,9958**	**0,50**

Tabel 3. Pengaruh Fungsi Aktivasi pada Regresi.

Konfigurasi kelima memberikan hasil terbaik dengan nilai R^2 sebesar 0,9958 dan MAE sebesar 0,50.

3.1.4 Pengaruh Learning Rate

Setelah diperoleh arsitektur terbaik, dilakukan pengujian terhadap learning rate.

No	Learning Rate	R^2	MAE
1	0,01	0,9958	0,50
2	0,05	0,9923	0,64
3	0,001	0,9953	0,52
4	0,005	0,9961	0,44

Tabel 4. Pengaruh Learning Rate pada Regresi.

Learning rate sebesar 0,005 memberikan hasil terbaik dengan R^2 sebesar 0,9961 dan MAE sebesar 0,44.

3.2 Hasil Eksperimen Klasifikasi

3.2.1 Pengaruh Jumlah Hidden Layer

Pengujian pada dataset Iris dilakukan dengan mengubah jumlah hidden layer.

No	Hidden Layer	Akurasi
1	2	0,5333
2	3	**0,9333**
3	4	0,3000
4	5	0,8000
5	6	0,3000

Tabel 5. Pengaruh Jumlah Hidden Layer pada Klasifikasi.

Hasil menunjukkan bahwa tiga hidden layer memberikan akurasi tertinggi pada pengujian awal, yaitu 0,9333.

3.2.2 Pengaruh Jumlah Neuron

No	Layer 1	Layer 2	Layer 3	Layer 4	Layer 5	Layer 6	Akurasi
1	3	6	9	6	9	8	1,0000
2	3	6	9	10	9	8	0,9667
3	4	12	11	10	9	8	0,9667
4	8	7	6	5	4	3	0,9000
5	3	3	3	3	3	3	0,3000

Tabel 6. Pengaruh Konfigurasi Neuron pada Klasifikasi.

Konfigurasi neuron 3-6-9-6-9-8 menghasilkan akurasi tertinggi sebesar 1,0000.

3.2.3 Pengaruh Fungsi Aktivasi

Pengujian fungsi aktivasi dilakukan menggunakan kombinasi ReLU, Sigmoid, dan Tanh.

No	Layer 1	Layer 2	Layer 3	Layer 4	Layer 5	Layer 6	Akurasi
1	ReLU	ReLU	ReLU	ReLU	Sigm	Tanh	0,9333
2	ReLU	ReLU	ReLU	Sigm	Sigm	Tanh	**1,0000**
3	ReLU	ReLU	Sigm	Sigm	Sigm	Tanh	0,6333
4	ReLU	Sigm	Sigm	Tanh	Tanh	Tanh	0,9333
5	ReLU	Sigm	Tanh	ReLU	ReLU	ReLU	0,9333

Tabel 7. Pengaruh Fungsi Aktivasi pada Klasifikasi.

Konfigurasi kelima memberikan hasil terbaik dengan nilai akurasi sebesar 1,0000.

3.2.4 Pengaruh Learning Rate

Setelah diperoleh arsitektur terbaik, dilakukan pengujian terhadap learning rate.

No	Learning Rate	Akurasi
1	0,01	0,9667
2	0,05	1,0000
3	0,001	1,0000
4	0,005	1,0000

Tabel 8. Pengaruh Learning Rate pada Klasifikasi.

Hasil menunjukkan bahwa learning rate 0,05, 0,001, dan 0,005 mampu menghasilkan akurasi sebesar 1,0000 pada eksperimen yang dilakukan.

3.2.5 Pengujian Fungsi Aktivasi Output

Pengujian terakhir dilakukan dengan mengganti fungsi aktivasi pada layer output.

No	Fungsi Aktivasi	Akurasi
1	Softmax	1,0000
2	ReLU	0,3333
3	Sigmoid	0,9667

Tabel 9. Perbandingan Fungsi Aktivasi Output.

Softmax memberikan hasil terbaik dengan akurasi 1,0000, sedangkan ReLU menghasilkan akurasi paling rendah sebesar 0,3333.

PEMBAHASAN

Secara keseluruhan, hasil penelitian menunjukkan bahwa kinerja Artificial Neural Network tidak hanya dipengaruhi oleh jumlah lapisan jaringan, tetapi merupakan hasil interaksi antara arsitektur, jumlah neuron, fungsi aktivasi, dan learning rate. Penambahan jumlah hidden layer dan neuron tidak selalu menghasilkan peningkatan kinerja karena jaringan dengan struktur yang lebih kompleks belum tentu sesuai dengan karakteristik dataset. Hal tersebut terlihat pada hasil penelitian, yaitu beberapa konfigurasi dengan jumlah layer atau neuron yang lebih besar justru menghasilkan kinerja yang lebih rendah.

Pada permasalahan regresi menggunakan dataset Boston Housing, konfigurasi learning rate sebesar 0,005 memberikan hasil paling baik dengan nilai R^2 sebesar 0,9961 dan MAE sebesar 0,44. Hasil tersebut menunjukkan bahwa model mampu menghasilkan prediksi dengan tingkat kesalahan yang relatif rendah. Sementara itu, pada permasalahan klasifikasi menggunakan dataset Iris, beberapa konfigurasi mampu mencapai akurasi sebesar 1,0000. Konfigurasi neuron 3-6-9-6-9-8, konfigurasi fungsi aktivasi ReLU-ReLU-ReLU-Sigmoid-Sigmoid-Tanh, serta learning rate 0,05, 0,001, dan 0,005 memberikan hasil akurasi tertinggi. Pada output layer, penggunaan Softmax juga memberikan akurasi sebesar 1,0000 sehingga menjadi pilihan yang paling sesuai dalam pengujian klasifikasi tiga kelas pada penelitian ini.

Hasil tersebut sejalan dengan penelitian Syaharuddin et al. (2022) yang menunjukkan bahwa jumlah hidden layer dan parameter pelatihan merupakan faktor yang perlu diperhatikan dalam menentukan arsitektur ANN. Pemilihan fungsi aktivasi juga menjadi faktor penting karena setiap fungsi memiliki karakteristik yang berbeda dalam proses transformasi data. Bouraya dan Belangour (2024) serta Dubey et al. (2022) menunjukkan bahwa perbedaan fungsi aktivasi dapat memberikan pengaruh terhadap kemampuan jaringan dalam mempelajari pola.

Berdasarkan seluruh pengujian yang telah dilakukan, konfigurasi terbaik untuk masing-masing parameter dirangkum pada Tabel 10. Tabel tersebut digunakan untuk memberikan gambaran mengenai konfigurasi yang menghasilkan kinerja paling baik pada masing-masing jenis permasalahan.

No	Parameter yg diuji	Konfigurasi Terbaik	R^2	MAE
1	Hidden Layer	3 hidden layer	0,9893	0,80
2	Konf. Neuron	16-5-3-8-17	0,9930	0,63
3	Fungsi Aktivasi	ReLU-Sigmoid-Tanh-ReLU-ReLU	0,9958	0,50
4	Learning Rate	0,005	0,9961	0,44

Tabel 10. Rekomendasi Konfigurasi ANN Terbaik pada Regresi.

Berdasarkan Tabel 10, konfigurasi yang memberikan hasil terbaik pada permasalahan regresi adalah learning rate sebesar 0,005 dengan nilai R^2 sebesar 0,9961 dan MAE sebesar 0,44. Konfigurasi neuron 16-5-3-8-17 juga memberikan peningkatan kinerja dengan R^2 sebesar 0,9930 dan MAE sebesar 0,63. Sementara itu, konfigurasi fungsi aktivasi ReLU-Sigmoid-Tanh-ReLU-ReLU menghasilkan R^2 sebesar 0,9958 dan MAE sebesar 0,50. Hasil tersebut menunjukkan bahwa pemilihan parameter pelatihan yang tepat dapat meningkatkan kemampuan model dalam menghasilkan prediksi dengan kesalahan yang lebih rendah.

No	Parameter yg diuji	Konfigurasi Terbaik	R^2	MAE
1	Hidden Layer	3 hidden layer	0,9333	1
2	Konf. Neuron	3-6-9-6-9-8	1,0000	2
3	Fungsi Aktivasi	ReLU-ReLU-ReLU-Sigmoid-Sigmoid-Tanh	1,0000	3
4	Learning Rate	0,05 / 0,001 / 0,005	1,0000	4
5	Output Activation	Softmax	1,000	5

Tabel 11. Rekomendasi Konfigurasi ANN Terbaik pada Klasifikasi.

Berdasarkan Tabel 11, konfigurasi neuron 3-6-9-6-9-8 menghasilkan akurasi tertinggi sebesar 1,0000. Konfigurasi fungsi aktivasi ReLU-ReLU-ReLU-Sigmoid-Sigmoid-Tanh juga menghasilkan akurasi sebesar 1,0000. Pada pengujian learning rate, nilai 0,05, 0,001, dan 0,005 sama-sama menghasilkan akurasi sebesar 1,0000. Sementara itu, penggunaan Softmax pada output layer menghasilkan akurasi sebesar 1,0000 dan menjadi konfigurasi yang paling sesuai pada

pengujian klasifikasi tiga kelas dalam penelitian ini.

Berdasarkan kedua tabel tersebut, dapat diketahui bahwa konfigurasi terbaik ANN berbeda antara tugas regresi dan klasifikasi. Pada regresi, indikator terbaik diperoleh dari kombinasi nilai R^2 tertinggi dan MAE terendah, sedangkan pada klasifikasi indikator utama adalah akurasi tertinggi. Hasil ini menunjukkan bahwa penentuan konfigurasi ANN perlu disesuaikan dengan jenis permasalahan dan karakteristik dataset yang digunakan.

PENUTUP

Berdasarkan hasil penelitian, dapat disimpulkan bahwa arsitektur dan parameter pelatihan ANN berpengaruh terhadap kinerja model regresi dan klasifikasi. Pada regresi Boston Housing, hasil terbaik diperoleh dengan learning rate 0,005 yang menghasilkan R^2 sebesar 0,9961 dan MAE sebesar 0,44. Pada klasifikasi Iris, konfigurasi neuron 3-6-9-6-9-8 dan fungsi Softmax pada output layer mampu menghasilkan akurasi sebesar 1,0000. Hasil penelitian juga menunjukkan bahwa penambahan hidden layer dan neuron tidak selalu meningkatkan kinerja, sehingga diperlukan proses pengujian dan parameter tuning untuk memperoleh konfigurasi yang sesuai dengan karakteristik dataset.

Penelitian selanjutnya dapat melakukan pengulangan eksperimen dengan beberapa random seed dan menggunakan cross-validation untuk memperoleh hasil yang lebih konsisten. Pengujian juga dapat dikembangkan dengan menambahkan parameter seperti epoch, batch size, optimizer, dan metode regularisasi serta menggunakan dataset yang lebih beragam untuk menguji kemampuan generalisasi model.

DAFTAR PUSTAKA

Bouraya, S., & Belangour, A. (2024). *A comparative analysis of activation functions in neural networks : unveiling categories*. *13*(5), 3301–3308. https://doi.org/10.11591/eei.v13i5.7274

Calvo-pardo, H., Mancini, T., & Olmo, J. (2023). Computers and Operations Research Optimal deep neural networks by maximization of the approximation power. *Computers and Operations Research*, *156*(April), 106264. https://doi.org/10.1016/j.cor.2023.106264

Dubey, S. R., Singh, S. K., & Chaudhuri, B. B. (2022). Activation Functions in Deep Learning: A Comprehensive Survey and Benchmark. *Neurocomputing*. https://doi.org/10.1016/j.neucom.2022.06.111

Ihzaniah, L. S., Setiawan, A., Wijaya, R. W. N. (2023). *Perbandingan Kinerja Metode Regresi KNearest Neighbor dan Metode Regresi Linear Berganda pada Data Boston Housing. Jambura Journal of Probability and Statistics.pdf*.

Li, Y., Ren, X., & Zhao, F. (2021). *applied sciences A Zeroth-Order Adaptive Learning Rate Method to Reduce Cost of Hyperparameter Tuning for Deep Learning*. *1*, 1–21.

Mangala, L., Timotius, A., & Andam, P. (2024). ScienceDirect ScienceDirect Comparison of Model Performance on Housing

Business Using Linear Regression , Random Forest Regressor , SVR , and Neural Network. *Procedia Computer Science*, *245*, 1139–1145. https://doi.org/10.1016/j.procs.2024.10.343

Rochmawati, N., Hidayati, H. B., Yamasari, Y., Tjahyaningtijas, H. P. A., Yustanti, W., & Prihanto, A. (2021). *Analisa learning rate dan batch size pada klasifikasi Covid menggunakan deep learning dengan optimizer Adam.pdf*. JIEET (Journal of Information Engineering and Educational Technology). https://doi.org/10.26740/jieet.v5n2.p44-48

Syaharuddin, S., Fatmawati, F., & Suprajitno, H. (2022). *Best architecture recommendations of ANN backpropagation based on combination of learning rate, momentum, and number of hidden layers.pdf*. JTAM (Jurnal Teori dan Aplikasi. https://doi.org/10.31764/jtam.v6i3.8524

Tirumala, S. S. (2025). *Exploring Underlying Features in Hidden Layers of Neural Network*. 1–16. https://pmc.ncbi.nlm.nih.gov/articles/PMC12473831