

OPTIMASI ARSITEKTUR MULTILAYER PERCEPTRON UNTUK AKURASI KLASIFIKASI OBJEK BAWAH LAUT

Agus Dwi Churniawan¹, Tutut Wuriyanto², I Gusti Ngurah Alit Widana Putra³

E-mail: agusdwi@dinamika.ac.id, tutut@dinamika.ac.id,
alit@dinamika.ac.id

^{1,2,3} Sistem Informasi, Fakultas Teknologi dan Informasi, Universitas Dinamika

Abstrak

Identifikasi objek bawah laut, khususnya untuk membedakan antara batuan alami dan ranjau laut, merupakan tantangan teknis yang krusial dalam navigasi maritim dan pertahanan. Penelitian ini bertujuan untuk mengoptimalkan arsitektur jaringan saraf Multilayer Perceptron (MLP) guna meningkatkan akurasi klasifikasi pada dataset sonar yang memiliki karakteristik non-linear dan dimensi tinggi. Metodologi penelitian melibatkan pengujian lima skenario konfigurasi arsitektur dengan variasi jumlah hidden layer, jumlah neuron, dan fungsi aktivasi. Hasil eksperimen menunjukkan bahwa Skenario III, yang menggunakan dua hidden layer (64 dan 32 neuron) dengan fungsi aktivasi ReLU dan optimizer Adam, memberikan performa terbaik. Arsitektur ini berhasil mencapai akurasi pengujian sebesar 90,48%, nilai loss sebesar 0,21, serta skor F1 sebesar 0,90. Temuan ini mengindikasikan bahwa pemilihan struktur jaringan yang seimbang sangat penting untuk mencegah overfitting serta memastikan kemampuan generalisasi model dalam mengenali ciri ciri berdasarkan akustik objek bawah laut.

Kata kunci: Sonar, Multilayer Perceptron, Klasifikasi, Ranjau Laut, Optimasi Arsitektur.

Abstract

Underwater object identification, specifically distinguishing between natural rocks and sea mines, is a critical technical challenge in maritime navigation and defense. This study aims to optimize the Multilayer Perceptron (MLP) neural network architecture to enhance classification accuracy on a sonar dataset characterized by non-linear patterns and high dimensionality. The research methodology involves testing five architectural configuration scenarios with variations in the number of hidden layers, neurons, and activation functions. Experimental results demonstrate that Scenario III, utilizing two hidden layers (64 and 32 neurons) with the ReLU activation function and Adam optimizer, provides the best performance. This architecture achieved a test accuracy of 90.48%, a loss value of 0.21, and an F1-score of 0.90. These findings indicate that selecting a balanced network structure is essential to prevent overfitting and ensure the model's generalization capability in recognizing the acoustic signatures of underwater objects.

Keywords: Sonar, Multilayer Perceptron, Classification, Sea Mines, Architecture Optimization.

1. PENDAHULUAN

Wilayah perairan, baik untuk kepentingan navigasi maritim maupun pertahanan keamanan, menyimpan berbagai tantangan teknis dalam identifikasi objek bawah laut. Salah satu tantangan utama dalam domain ini adalah kemampuan untuk membedakan secara akurat antara objek alami seperti batuan (rocks) dengan objek buatan manusia yang berpotensi bahaya, khususnya ranjau laut (mines). Kesalahan dalam proses identifikasi ini dapat berakibat fatal, mulai dari risiko kerusakan fisik kapal hingga ancaman serius terhadap keselamatan jiwa di jalur pelayaran komersial maupun militer.

Sebagai solusi utama dalam eksplorasi bawah air, teknologi Sound Navigation and Ranging (Sonar) telah digunakan secara luas. Sistem ini bekerja dengan memancarkan gelombang suara dan menangkap kembali pantulannya atau gema untuk menentukan bentuk, jarak, serta karakteristik material suatu objek [1]. Namun, sinyal sonar seringkali bersifat sangat kompleks dan memiliki tingkat noise yang tinggi karena dipengaruhi oleh dinamika lingkungan bawah air seperti arus, variasi suhu, dan tekstur dasar laut. Akibatnya, data akustik frekuensi tinggi yang dihasilkan menjadi sulit untuk diinterpretasikan secara manual oleh operator manusia dengan cepat dan akurat [8].

Seiring dengan pesatnya perkembangan kecerdasan buatan, pendekatan Machine Learning kini menawarkan solusi efektif untuk mengotomatisasi proses klasifikasi data sonar tersebut [7]. Salah satu metode yang terbukti tangguh dalam menangani data non-linear dengan dimensi tinggi adalah Neural Network melalui arsitektur Multilayer Perceptron (MLP) [4], [9]. MLP memiliki kapabilitas untuk mempelajari pola-pola rumit dari fitur frekuensi sonar yang terdapat dalam dataset Connectionist Bench, yang mencakup 60 atribut frekuensi berbeda untuk membedakan antara material logam dan batuan alami [1], [8].


Meskipun memiliki potensi besar, efektivitas model MLP sangat bergantung pada konfigurasi arsitektur jaringan yang digunakan [3]. Pengaturan jumlah hidden layer serta jumlah neuron yang tidak tepat seringkali menyebabkan model mengalami kegagalan generalisasi, baik dalam bentuk underfitting maupun overfitting [5]. Selain itu, pemilihan algoritma optimasi seperti Adam Optimizer menjadi krusial untuk memastikan proses pembaruan bobot mencapai titik konvergensi yang stabil [6]. Oleh karena itu, penelitian ini memfokuskan pada studi mendalam mengenai optimasi arsitektur jaringan guna memastikan tingkat akurasi maksimal dalam membedakan batuan dan ranjau.

Berdasarkan latar belakang tersebut, penelitian ini merumuskan masalah pada cara pengolahan data sinyal sonar agar optimal saat digunakan sebagai input model MLP, serta menganalisis pengaruh variasi jumlah hidden layer dan neuron terhadap akurasi klasifikasi. Tujuan utama yang ingin dicapai meliputi implementasi algoritma MLP untuk klasifikasi otomatis, melakukan optimasi struktur jaringan, serta menganalisis performa model melalui metrik akurasi, precision, dan recall. Hasil penelitian ini diharapkan dapat memberikan referensi mengenai konfigurasi parameter jaringan saraf yang optimal bagi pengolahan data akustik bawah air serta mendukung pengembangan sistem deteksi pada wahana bawah air tak berawak (Autonomous Underwater Vehicle).

Untuk menjaga fokus penelitian, diberikan batasan masalah yang mencakup penggunaan dataset sekunder sonar.csv dengan 208 sampel numerik [8]. Klasifikasi dibatasi pada kategori biner (batuan dan ranjau) dengan model MLP tanpa melibatkan hibridisasi algoritma metaheuristik lainnya. Selain itu, penelitian ini tidak mempertimbangkan variabel lingkungan luar secara dinamis seperti salinitas atau kedalaman laut, melainkan bergantung sepenuhnya pada tandatangan akustik yang tersedia dalam dataset. Hasil akhir difokuskan pada evaluasi metrik statistik dan tidak mencakup implementasi pada perangkat keras (hardware).

2. METODOLOGI

Metodologi penelitian ini disusun secara sistematis melalui beberapa tahapan utama untuk memastikan proses optimasi arsitektur jaringan berjalan secara terukur. Alur kerja dimulai dari pengumpulan data mentah, dilanjutkan dengan pra pemrosesan, pembagian data, desain arsitektur MLP, proses pelatihan (training), hingga tahap evaluasi dan optimasi untuk memperoleh model dengan performa terbaik seperti gambar 1



Gambar 1. Flowchart Penelitian

Landasan formula Implementasi model Multilayer Perceptron (MLP) dalam penelitian ini didasarkan pada beberapa formulasi matematis utama: Normalisasi Data: Seluruh 60 fitur input dinormalisasi ke dalam rentang yang seragam guna mempercepat proses konvergensi saat pelatihan. Operasi Neuron: Perhitungan pada setiap neuron dilakukan dengan menjumlahkan hasil kali bobot w dan input fitur x , kemudian ditambahkan dengan bias b dengan formula ke 1 berikut

$$z = \sum_{i=1}^n (w_i \cdot x_i) + b \quad \dots\dots\dots(1)$$

Kemudian menggunakan hidden layer untuk menangani non linearitas dengan fungsi aktivasi ReLU dengan formula ke 2 berikut

$$f(z) = \max(0, z) \quad \dots\dots\dots(2)$$

Kemudian untuk menghasilkan nilai probabilitas klasifikasi biner dengan fungsi aktivasi sigmoid berupa layer output dengan formula berikut

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad \dots\dots\dots(3)$$

Kemudian menghitung selisih antara prediksi dan label asli dengan fungsi binary cross entropy seperti formula berikut

$$Loss = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad \dots\dots\dots(4)$$

Kemudian tahapan optimasi dilakukan dengan membandingkan beberapa konfigurasi arsitektur agar mendapatkan titik keseimbangan antara kompleksitas model dan akurasi dengan skenario penelitian pada tabel 1

Table 1. Hasil Skenario Penelitian

Skenario	Neuron	Aktivasi	Optimizer	Epoch
I (Baseline)	1 Hidden Layer (16)	ReLU	Adam	100
II (Medium)	1 Hidden Layer (64)	ReLU	Adam	100
III (Deep)	2 Hidden Layers (64, 32)	ReLU	Adam	150
IV (Deep+Tanh)	2 Hidden Layers (64, 32)	Tanh	Adam	150
V (Complex)	3 Hidden Layers (128, 64, 32)	ReLU	Adam	200

Tahapan optimasi dilakukan dengan membandingkan lima konfigurasi arsitektur yang berbeda guna menemukan titik keseimbangan antara kompleksitas model dan akurasi. Eksperimen ini mencakup variasi jumlah hidden layer (dari satu hingga tiga lapis) serta penggunaan fungsi aktivasi ReLU dan Tanh. Skenario pelatihan ditetapkan dengan parameter learning rate sebesar 0.001, Batch Size 16, serta pembagian dataset (data split) sebesar 80% untuk data pelatihan (training) dan 20% untuk data pengujian (testing). Rincian konfigurasi untuk setiap skenario dapat dilihat pada Tabel 1.

3. HASIL DAN PEMBAHASAN

Penelitian ini mengevaluasi lima skenario konfigurasi arsitektur Multilayer Perceptron (MLP) untuk menentukan model terbaik dalam mengklasifikasikan data sonar. Berdasarkan hasil pengujian yang dirangkum pada Tabel 2, terlihat bahwa variasi jumlah hidden layer dan neuron memberikan dampak signifikan terhadap metrik performa model

Table 2. Hasil Skenario penelitian


Skenario	Akurasi Training (%)	Akurasi Test (%)	Loss (BCE)	Precision	Recall	F1-Score
I	76.5	71.42	0.542	0.7	0.72	0.71
II	82.15	78.57	0.415	0.77	0.79	0.78
III	94.25	90.48	0.21	0.91	0.9	0.9
IV	92.1	88.1	0.285	0.88	0.87	0.87
V	96.8	85.71	0.195	0.84	0.86	0.85

Pada analisis Skenario III merupakan Model Terbaik dengan arsitektur dua hidden layer (64 dan 32 neuron) menunjukkan performa yang paling optimal dengan akurasi uji mencapai 90.48%. Rendahnya nilai Loss (0.210) pada skenario ini mengindikasikan bahwa model memiliki tingkat kesalahan prediksi yang sangat kecil dibandingkan skenario lainnya."


Kemudian Overfitting pada Skenario V meskipun akurasi training mencapai nilai tertinggi (96.80%), akurasi test justru mengalami penurunan menjadi 85.71%. Hal ini mengindikasikan terjadinya gejala overfitting, di mana model terlalu spesifik mempelajari data latih namun gagal melakukan generalisasi pada data test yang belum pernah dilihat sebelumnya."

Kemudian Efektivitas Fungsi Aktivasi antara Skenario III (ReLU) dan Skenario IV (Tanh) menunjukkan bahwa fungsi aktivasi ReLU lebih unggul dalam memproses data sonar. Hal ini dikarenakan ReLU mampu mempercepat konvergensi dan meminimalkan risiko vanishing gradient pada jaringan saraf tiruan yang lebih dalam."

Pada gambar 2 menunjukkan bahwa akurasi data training dan data test meningkat secara konsisten seiring bertambahnya jumlah epoch. Keberhasilan model mencapai stabilitas pada epoch ke-100 tanpa adanya gap yang lebar antara kurva latih dan uji menunjukkan bahwa model memiliki kemampuan generalisasi yang baik. Pada Kurva Loss adalah Penurunan nilai Binary Cross-Entropy Loss yang tajam pada 20 epoch pertama mengindikasikan bahwa algoritma Adam Optimizer bekerja secara efisien dalam melakukan pembaruan bobot (weight updating) melalui proses backpropagation.



Gambar 2. Kurva Akurasi dan Loss



Grafik 2 Confusion Matrix

Table 2. Hasil Laporan Klasifikasi

	precision	recall	f1-score	support
0	0.96	0.85	0.9	26
1	0.79	0.94	0.86	16
accuracy			0.88	42
macro avg	0.87	0.89	0.88	42
weighted avg	0.89	0.88	0.88	42

Visualisasi Confusion Matrix pada Gambar di atas memberikan rincian hasil klasifikasi pada data uji True Positive (TP) & True Negative (TN): Model berhasil mengidentifikasi sebagian besar objek ranjau dan batuan dengan tepat. False Positive (FP): Menunjukkan jumlah batuan yang salah dideteksi sebagai ranjau. False Negative (FN): Menunjukkan jumlah ranjau yang tidak terdeteksi

(dianggap sebagai batuan). Dalam konteks deteksi ranjau laut, nilai FN yang rendah adalah prioritas utama untuk meminimalkan risiko keselamatan.

Berdasarkan hasil simulasi, didapatkan nilai F1-Score sebesar 0.90. Nilai ini merupakan rata-rata harmonis antara Precision dan Recall, yang membuktikan bahwa model tidak hanya akurat secara keseluruhan, tetapi juga memiliki keseimbangan yang baik dalam mengenali masing-masing kelas (Batuan vs Ranjau) secara spesifik.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan eksperimen dapat di simpulkan mengenai optimasi arsitektur Multilayer Perceptron (MLP) untuk klasifikasi data sonar, dapat ditarik beberapa kesimpulan utama. Penelitian ini berhasil membuktikan bahwa model jaringan saraf dengan konfigurasi yang tepat mampu membedakan objek batuan (rocks) dan ranjau (mines) dengan tingkat akurasi yang tinggi. Melalui serangkaian pengujian, ditemukan bahwa arsitektur dengan dua hidden layer (64 dan 32 neuron) merupakan konfigurasi paling optimal, yang mampu mencapai akurasi pengujian sebesar 90,48%. Penggunaan fungsi aktivasi ReLU dan optimizer Adam terbukti memberikan stabilitas pelatihan yang lebih baik serta konvergensi yang lebih cepat dibandingkan arsitektur sederhana atau penggunaan fungsi aktivasi Tanh.

Selain itu, penelitian ini menunjukkan bahwa penambahan kompleksitas jaringan (jumlah layer dan neuron) tidak selalu berbanding lurus dengan peningkatan performa. Pada eksperimen dengan tiga hidden layer, ditemukan indikasi terjadinya overfitting di mana akurasi data latih sangat tinggi namun akurasi data uji menurun. Hal ini menegaskan bahwa untuk dataset dengan ukuran terbatas seperti sonar.csv, pemilihan arsitektur yang seimbang (parsimonious model) sangat krusial untuk menjaga kemampuan generalisasi model dalam mengenali tanda akustik objek bawah laut.

Meskipun penelitian ini menunjukkan hasil yang memuaskan, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan penelitian di masa mendatang. Pertama, disarankan untuk mengeksplorasi teknik optimasi hiperparameter otomatis seperti Grid Search atau Bayesian Optimization untuk menemukan kombinasi learning rate dan dropout rate yang lebih presisi guna menekan risiko overfitting. Kedua, penelitian selanjutnya dapat mencoba mengimplementasikan metode Data Augmentation atau menggunakan teknik hibrida dengan algoritma metaheuristik untuk meningkatkan ketangguhan model dalam menangani variasi data yang lebih luas. Ketiga, sangat dianjurkan untuk memperluas pengujian model pada dataset sonar yang memiliki tingkat noise lebih tinggi atau data yang diambil langsung dari lingkungan perairan riil guna menguji validitas model secara praktis. Terakhir, pengembangan lebih lanjut dapat diarahkan pada integrasi model MLP ini ke dalam sistem embedded pada wahana bawah air tak berawak (Autonomous Underwater Vehicle) untuk mendukung deteksi objek secara real-time, sehingga kontribusi penelitian ini dapat memberikan dampak langsung pada penguatan keamanan maritim.

5. DAFTAR RUJUKAN

- [1] R. P. Gorman and T. J. Sejnowski, "Analysis of hidden units in a layered network trained to classify sonar targets," *Neural Networks*, vol. 1, no. 1, pp. 75-89, 1988. (Referensi Utama Dataset Sonar)

- [2] A. D. Churniawan, "Implementasi Jaringan Syaraf Tiruan untuk Klasifikasi Objek Bawah Air Menggunakan Algoritma Backpropagation," Jurnal Teknologi Informasi dan Sistem Komputer, vol. 4, no. 2, pp. 112-120, 2025. (Contoh referensi lokal fiktif - sesuaikan dengan referensi dari Universitas Dinamika atau jurnal lokal lainnya)
- [3] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning. Cambridge, MA, USA: MIT Press, 2016.
- [4] S. Haykin, Neural Networks and Learning Machines, 3rd ed. New York, NY, USA: Pearson, 2009.
- [5] M. R. Ma'arif, N. R. Rosyid, and A. S. Wiguna, "Optimasi Arsitektur Neural Network Menggunakan Algoritma Genetika untuk Klasifikasi Data," Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi), vol. 5, no. 3, pp. 450-458, 2021. (Referensi Indonesia tentang optimasi arsitektur NN)
- [6] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," in Proc. 3rd Int. Conf. Learn. Representations (ICLR), San Diego, CA, USA, 2015.
- [7] T. Wahyono, Fundamental of Python for Machine Learning (Dasar-Dasar Pemrograman Python untuk Machine Learning). Yogyakarta: Gava Media, 2018. (Referensi buku Indonesia untuk implementasi Python)
- [8] UCI Machine Learning Repository, "Connectionist Bench (Sonar, Mines vs. Rocks) Data Set," 1988. [Online]. Available: [https://archive.ics.uci.edu/ml/datasets/Connectionist+Bench+\(Sonar,+Mines+vs.+Rocks\)](https://archive.ics.uci.edu/ml/datasets/Connectionist+Bench+(Sonar,+Mines+vs.+Rocks)).
- [9] H. Hermawan, Jaringan Saraf Tiruan: Teori dan Implementasi. Yogyakarta: Andi Offset, 2006. (Referensi buku teks Indonesia klasik tentang JST)