



Optimasi *Artificial Neural Network* untuk Klasifikasi Gaya Belajar Mahasiswa Menggunakan Model Visual, Auditori, dan Kinestetik (VAK)

Agung Wicakono^{1*}, Zein Hani Pradana², Prasetyo Yuliantoro³, Hasri Wulan Nugraheni⁴

¹⁻⁴ Telkom University Purwokerto, Indonesia

*Penulis Korespondensi: agungwicaksonopwt@telkomuniversity.ac.id

Abstract. This study proposes an optimized Artificial Neural Network (ANN) framework for the automatic classification of student learning styles based on the Visual, Auditory, and Kinesthetic (VAK) model to support educational personalization. The system utilizes data from a 36-item questionnaire, which are preprocessed using z-score standardization and encoded into numerical features. Several ANN configurations were evaluated to examine the influence of network depth, activation functions, regularization strength (λ ranging from 1×10^{-4} to 1×10^{-2}), and the number of training iterations between 500 and 2000. Model training employed the Adam optimizer combined with early stopping to ensure stable and efficient convergence. The results demonstrate that proper data standardization and suitable regularization significantly enhance model generalization and training stability. The optimal model consists of two hidden layers with 64 and 32 neurons using ReLU activation and $\lambda = 1 \times 10^{-2}$, achieving an accuracy of 91.9% and a macro-F1 score of 0.908. Overall, systematic hyperparameter optimization improves the robustness and reliability of ANN-based learning style classification for adaptive learning systems.

Keywords: Artificial Neural Network; Hyperparameter Optimization; Learning Style Classification; Regularization; VAK Model.

Abstrak. Studi ini mengusulkan kerangka kerja Jaringan Saraf Buatan (ANN) yang dioptimalkan untuk klasifikasi otomatis gaya belajar siswa berdasarkan model Visual, Auditori, dan Kinestetik (VAK) untuk mendukung personalisasi pendidikan. Sistem ini menggunakan data dari kuesioner 36 item, yang diproses terlebih dahulu menggunakan standardisasi z-score dan dikodekan menjadi fitur numerik. Beberapa konfigurasi ANN dievaluasi untuk memeriksa pengaruh kedalaman jaringan, fungsi aktivasi, kekuatan regularisasi (λ berkisar dari 1×10^{-4} hingga 1×10^{-2}), dan jumlah iterasi pelatihan antara 500 dan 2000. Pelatihan model menggunakan pengoptimal Adam yang dikombinasikan dengan penghentian awal untuk memastikan konvergensi yang stabil dan efisien. Hasilnya menunjukkan bahwa standardisasi data yang tepat dan regularisasi yang sesuai secara signifikan meningkatkan generalisasi model dan stabilitas pelatihan. Model optimal terdiri dari dua lapisan tersembunyi dengan 64 dan 32 neuron menggunakan aktivasi ReLU dan $\lambda = 1 \times 10^{-2}$, mencapai akurasi 91,9% dan skor makro-F1 sebesar 0,908. Secara keseluruhan, optimasi hiperparameter sistematis meningkatkan kekokohan dan keandalan klasifikasi gaya belajar berbasis ANN untuk sistem pembelajaran adaptif.

Kata kunci: Artificial Neural Network; Klasifikasi Gaya Belajar; Model VAK; Optimasi Hiperparameter; Regularisasi

1. LATAR BELAKANG

Perkembangan teknologi informasi dan kecerdasan buatan dalam lima tahun terakhir telah mendorong pemanfaatan pendekatan data-driven secara masif dalam sistem pendidikan digital. Konsep learning analytics dan educational data mining semakin banyak diterapkan untuk menganalisis perilaku belajar peserta didik dan mendukung pengembangan sistem pembelajaran adaptif berbasis kecerdasan buatan (Romero & Ventura, 2020; Siemens et al., 2022; Viberg et al., 2020). Pendekatan ini menekankan pentingnya pemodelan karakteristik peserta didik secara akurat untuk meningkatkan efektivitas dan personalisasi pembelajaran.

Salah satu karakteristik yang sering digunakan dalam sistem pembelajaran adaptif adalah gaya belajar peserta didik. Dalam konteks modern, gaya belajar tidak lagi dipandang

sebagai kategori statis, melainkan sebagai representasi pola preferensi belajar yang dapat dipelajari secara komputasional dari data perilaku dan respons peserta didik (Karamouzis & Vrettaros, 2021; Özpolat & Akar, 2020). Model Visual, Auditori, dan Kinestetik (VAK) masih banyak digunakan sebagai kerangka operasional karena kesederhanaannya dan kemudahan integrasi ke dalam instrumen pengumpulan data digital, khususnya kuesioner berbasis sistem informasi pendidikan (Chen et al., 2021; Andari, 2022).

Namun demikian, berbagai penelitian mutakhir menunjukkan bahwa identifikasi gaya belajar secara manual atau berbasis penilaian subjektif memiliki keterbatasan, antara lain rendahnya konsistensi, bias persepsi responden, serta ketidakmampuan menangkap pola kompleks dan tumpang tindih antar preferensi belajar (Rogowsky et al., 2020; Knoll et al., 2021). Oleh karena itu, pendekatan komputasional berbasis machine learning semakin dipandang sebagai solusi yang lebih objektif dan terukur untuk melakukan klasifikasi gaya belajar secara otomatis.

Seiring meningkatnya ketersediaan data pendidikan digital, berbagai algoritma machine learning telah diterapkan untuk klasifikasi gaya belajar, termasuk support vector machine, random forest, dan k-nearest neighbor. Namun, data pendidikan umumnya bersifat nonlinier, berdimensi tinggi, dan mengandung ketergantungan antar fitur, sehingga menuntut model yang memiliki kemampuan representasi yang kuat (Huang et al., 2019; Liao et al., 2021). Dalam konteks ini, Jaringan Saraf Tiruan (Artificial Neural Network/ANN) menunjukkan keunggulan dalam memodelkan hubungan nonlinier dan pola kompleks pada data perilaku belajar mahasiswa (Castillo et al., 2020; Uddin & Kar, 2020).

Penelitian terkini menunjukkan bahwa ANN mampu mencapai kinerja yang kompetitif dalam klasifikasi gaya belajar, namun performa model sangat dipengaruhi oleh konfigurasi arsitektur dan hiperparameter yang digunakan (Al-Badarenah & Alsakran, 2020; Karamouzis & Vrettaros, 2021). Banyak studi masih berfokus pada peningkatan akurasi tanpa mengevaluasi aspek stabilitas pelatihan, kemampuan generalisasi, dan ketahanan model terhadap overfitting, padahal faktor-faktor tersebut sangat krusial dalam implementasi sistem nyata berbasis teknologi informasi (Zhang et al., 2021; Huang et al., 2022).

Penelitian deep learning dalam lima tahun terakhir menegaskan bahwa optimasi arsitektur jaringan dan penerapan teknik regularisasi memiliki peran penting dalam meningkatkan ketangguhan model. Teknik seperti L2 regularization, dropout, dan early stopping terbukti mampu mengurangi overfitting dan meningkatkan stabilitas konvergensi pelatihan jaringan saraf (Srivastava et al., 2020; Li et al., 2021). Selain itu, standarisasi dan

normalisasi data input juga berkontribusi signifikan terhadap efisiensi pelatihan dan konsistensi performa model ANN (Ioffe & Szegedy, 2020; Wu et al., 2021).

Dalam konteks sistem pembelajaran cerdas, stabilitas dan generalisasi model menjadi aspek yang semakin mendapat perhatian. Studi terbaru pada intelligent tutoring systems dan knowledge tracing menekankan bahwa model prediksi harus memiliki ketahanan terhadap variasi data agar dapat menghasilkan rekomendasi pembelajaran yang konsisten dan dapat diandalkan (Shen et al., 2024; Zanellati et al., 2024). Selain itu, integrasi model kecerdasan buatan yang semakin kompleks ke dalam sistem pendidikan menuntut pendekatan optimasi hiperparameter yang sistematis agar model tetap stabil dan dapat dikalibrasi dengan baik (Xu et al., 2024; Wang et al., 2025).

Berdasarkan tinjauan tersebut, masih terdapat celah penelitian dalam pengembangan model ANN untuk klasifikasi gaya belajar yang secara eksplisit mengevaluasi pengaruh optimasi arsitektur dan regularisasi terhadap stabilitas, generalisasi, dan kalibrasi probabilitas model. Oleh karena itu, penelitian ini berfokus pada optimasi sistematis arsitektur dan hiperparameter ANN untuk klasifikasi gaya belajar mahasiswa berdasarkan model VAK, dengan tujuan menghasilkan model yang robust dan siap diintegrasikan ke dalam sistem pembelajaran adaptif berbasis teknologi informasi.

2. KAJIAN TEORITIS

Bagian ini menguraikan teori-teori yang relevan sebagai landasan konseptual penelitian serta meninjau hasil penelitian terdahulu yang berkaitan dengan klasifikasi gaya belajar dan penerapan Artificial Neural Network (ANN) dalam sistem pembelajaran adaptif. Kajian teoretis ini bertujuan untuk memberikan acuan ilmiah dan memperjelas posisi penelitian yang dilakukan dalam konteks pengembangan keilmuan di bidang teknologi informasi dan pendidikan berbasis data.

Personalisasi Pembelajaran dan Learning Analytics

Perkembangan teknologi informasi telah mendorong penerapan personalisasi pembelajaran berbasis data dalam sistem pendidikan modern. Personalisasi pembelajaran bertujuan menyesuaikan strategi dan konten pembelajaran dengan karakteristik peserta didik agar proses belajar menjadi lebih efektif. Dalam konteks ini, learning analytics dan educational data mining berperan penting dalam menganalisis data pembelajaran untuk memahami pola perilaku belajar serta mendukung pengambilan keputusan pedagogis berbasis bukti (Romero & Ventura, 2020).

Pendekatan learning analytics memungkinkan pemanfaatan data aktivitas dan respons peserta didik untuk membangun sistem pembelajaran adaptif yang responsif terhadap kebutuhan individu. Oleh karena itu, pemodelan karakteristik belajar peserta didik secara otomatis menjadi komponen penting dalam pengembangan sistem pembelajaran berbasis teknologi.

Gaya Belajar dan Model Visual, Auditori, dan Kinestetik (VAK)

Gaya belajar menggambarkan kecenderungan individu dalam menerima dan memproses informasi selama proses pembelajaran. Model Visual, Auditori, dan Kinestetik (VAK) merupakan salah satu pendekatan yang banyak digunakan untuk mengelompokkan gaya belajar berdasarkan preferensi modalitas sensorik. Model ini sering diimplementasikan sebagai kerangka operasional dalam penelitian pendidikan berbasis teknologi karena kesederhanaan dan kemudahannya dalam penerapan instrumen pengumpulan data (Castillo et al., 2020).

Dalam praktiknya, model VAK umumnya direpresentasikan melalui instrumen kuesioner yang berisi pernyataan terkait preferensi belajar. Pendekatan ini sesuai digunakan sebagai masukan awal dalam sistem pembelajaran adaptif, khususnya ketika dikombinasikan dengan metode komputasional untuk melakukan klasifikasi otomatis gaya belajar.

Praproses Data dan Standarisasi Z-Score

Data kuesioner yang digunakan dalam klasifikasi gaya belajar sering kali memiliki rentang nilai yang berbeda antaratribut. Perbedaan skala ini dapat memengaruhi proses pelatihan dan stabilitas model pembelajaran mesin, terutama pada jaringan saraf. Oleh karena itu, tahap praproses data menjadi langkah penting sebelum pelatihan model dilakukan.

Standarisasi z-score merupakan teknik praproses yang umum digunakan untuk menyamakan skala fitur dengan mengubah data sehingga memiliki nilai rata-rata nol dan simpangan baku satu. Teknik ini terbukti dapat meningkatkan stabilitas pelatihan, mempercepat konvergensi, serta meningkatkan kemampuan generalisasi model ANN (Kim et al., 2024).

Artificial Neural Network untuk Klasifikasi Gaya Belajar

Artificial Neural Network merupakan metode machine learning yang memiliki kemampuan tinggi dalam memodelkan hubungan nonlinier dan pola kompleks antarfitur. ANN banyak digunakan pada permasalahan klasifikasi multikelas karena fleksibilitas arsitekturnya dalam mempelajari representasi data berdimensi tinggi. Dalam konteks klasifikasi gaya belajar, ANN umumnya diimplementasikan dalam bentuk multilayer perceptron dengan satu atau lebih lapisan tersembunyi (Uddin & Kar, 2020).

Kedalaman arsitektur dan jumlah neuron pada lapisan tersembunyi memengaruhi kapasitas model dalam mempelajari pola data. Oleh karena itu, evaluasi berbagai konfigurasi arsitektur ANN diperlukan untuk memperoleh keseimbangan antara kinerja klasifikasi dan kemampuan generalisasi model.

Regularisasi dan Stabilitas Model ANN

Meskipun ANN memiliki kemampuan representasi yang tinggi, model ini juga rentan terhadap masalah overfitting. Untuk mengatasi hal tersebut, teknik regularisasi diterapkan guna membatasi kompleksitas model dan meningkatkan stabilitas pelatihan. Regularisasi L2 atau weight decay merupakan salah satu teknik yang umum digunakan untuk mengendalikan besarnya bobot jaringan sehingga model cenderung menghasilkan solusi yang lebih sederhana dan stabil.

Selain regularisasi, mekanisme early stopping digunakan untuk menghentikan proses pelatihan ketika kinerja validasi tidak lagi meningkat. Kombinasi regularisasi dan early stopping terbukti efektif dalam meningkatkan kemampuan generalisasi ANN dan menjaga stabilitas konvergensi selama pelatihan (Srivastava et al., 2020).

Evaluasi Kinerja Klasifikasi

Evaluasi kinerja model klasifikasi gaya belajar dilakukan menggunakan metrik yang sesuai dengan permasalahan multikelas. Selain akurasi, metrik macro-F1 digunakan untuk mengevaluasi kinerja model secara seimbang pada setiap kelas gaya belajar. Penggunaan macro-F1 penting untuk memastikan bahwa model tidak bias terhadap kelas tertentu dan mampu memberikan performa yang konsisten pada seluruh kategori gaya belajar (Hinojosa Lee et al., 2024).

3. METODE PENELITIAN

Metodologi penelitian ini dirancang untuk mengembangkan dan mengevaluasi model Artificial Neural Network (ANN) yang teroptimasi dalam melakukan klasifikasi gaya belajar mahasiswa berdasarkan model Visual, Auditori, dan Kinestetik (VAK). Tahapan penelitian meliputi pengumpulan data, praproses data, perancangan arsitektur ANN, pelatihan dan optimasi model, serta evaluasi kinerja klasifikasi.

Data dan Sumber Data

Data penelitian diperoleh dari kuesioner gaya belajar mahasiswa yang terdiri atas 36 butir pertanyaan. Setiap butir merepresentasikan indikator preferensi belajar berdasarkan model VAK dan digunakan sebagai fitur masukan pada model ANN. Pendekatan kuesioner

sebagai sumber data awal masih relevan untuk klasifikasi gaya belajar ketika dipadukan dengan metode komputasional (Castillo et al., 2020; Uddin & Kar, 2020).

Praproses Data

1) Pengkodean Data

Jawaban kuesioner dikonversi ke dalam bentuk numerik sehingga setiap responden direpresentasikan sebagai vektor fitur berdimensi 36.

2) Standarisasi Z-Score

Untuk mengatasi perbedaan skala antarfitur, dilakukan standarisasi z-score dengan persamaan:

$$z_i = \frac{x_i - \mu}{\sigma}$$

Standarisasi ini bertujuan meningkatkan stabilitas pelatihan dan mempercepat konvergensi model ANN, sebagaimana ditunjukkan pada berbagai studi pemodelan jaringan saraf (Kim et al., 2024).

3) Pembagian Data

Dataset dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan stratified sampling guna menjaga proporsi kelas.

Arsitektur Artificial Neural Network

Model ANN yang digunakan merupakan Multilayer Perceptron dengan satu hingga dua lapisan tersembunyi. ANN dipilih karena kemampuannya memodelkan hubungan nonlinier pada data berdimensi tinggi dan kompleks (Zhang et al., 2020).

Fungsi Aktivasi

Lapisan tersembunyi menggunakan fungsi aktivasi ReLU:

$$f(x) = \max(0, x)$$

sedangkan lapisan keluaran menggunakan fungsi Softmax untuk klasifikasi multikelas:

$$\text{Softmax}(z_j) = \frac{e^{z_j}}{\sum_{k=1}^C e^{z_k}}$$

Penggunaan ReLU terbukti efektif dalam meningkatkan stabilitas pelatihan jaringan saraf (He et al., 2015).

Fungsi Loss dan Regularisasi

Fungsi Loss

Masalah klasifikasi multikelas diselesaikan menggunakan fungsi categorical cross-entropy:

$$\mathcal{L} = - \sum_{j=1}^C y_j \log(\hat{y}_j)$$

Fungsi ini umum digunakan pada ANN untuk klasifikasi multikelas (Goodfellow et al., 2016).

Regularisasi L2

Untuk mengurangi *overfitting*, diterapkan regularisasi L2:

$$\mathcal{L}_{reg} = \mathcal{L} + \lambda \sum_{i=1}^N w_i^2$$

Regularisasi L2 terbukti efektif dalam meningkatkan generalisasi dan stabilitas model ANN (Srivastava et al., 2020).

Pelatihan dan Optimasi Model

Pelatihan model dilakukan menggunakan optimizer Adam, yang mengadaptasi *learning rate* secara otomatis berdasarkan estimasi momen gradien (Kingma & Ba, 2014):

$$w_{t+1} = w_t - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}}$$

Untuk mencegah *overfitting*, digunakan mekanisme *early stopping* dengan memantau kinerja data validasi selama proses pelatihan (Bai et al., 2021).

Evaluasi Kinerja Model

Evaluasi kinerja dilakukan menggunakan akurasi dan macro-F1. Penggunaan macro-F1 penting untuk memastikan evaluasi yang seimbang pada setiap kelas gaya belajar (Hinojosa Lee et al., 2024):

1) Akurasi

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2) Precision dan Recall

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

3) F1-Score

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

4) Macro-F1

$$Macro - F1 = \frac{1}{C} \sum_{j=1}^C F1_j$$

4. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil eksperimen klasifikasi gaya belajar mahasiswa menggunakan berbagai konfigurasi Artificial Neural Network (ANN) serta membahas pengaruh praproses data, arsitektur jaringan, regularisasi, dan jumlah iterasi pelatihan terhadap kinerja model. Evaluasi dilakukan menggunakan data uji dengan metrik akurasi dan macro-F1 untuk memastikan performa yang seimbang pada seluruh kelas gaya belajar.

Hasil Eksperimen

Serangkaian eksperimen dilakukan untuk mengevaluasi dua belas konfigurasi Artificial Neural Network (ANN) dalam klasifikasi gaya belajar. Setiap konfigurasi divariasikan berdasarkan parameter arsitektur dan pelatihan, meliputi jumlah lapisan tersembunyi, jumlah neuron pada setiap lapisan, fungsi aktivasi, penerapan standarisasi data, koefisien regularisasi λ , serta jumlah iterasi pelatihan. Tujuan utama dari eksperimen ini adalah untuk menentukan konfigurasi optimal yang mampu memberikan keseimbangan terbaik antara akurasi, stabilitas model, dan efisiensi komputasi.

Ringkasan kinerja setiap model disajikan pada Tabel 1, dengan metrik akurasi dan macro-F1 digunakan sebagai indikator utama evaluasi. Hasil pengujian menunjukkan bahwa seluruh model menghasilkan kinerja yang konsisten dan cukup tinggi, dengan nilai akurasi berkisar antara 0,898 hingga 0,919 serta nilai macro-F1 antara 0,883 hingga 0,908. Hal ini menunjukkan kemampuan ANN yang baik dalam mengenali pola gaya belajar berdasarkan data perilaku. Selain itu, hasil eksperimen mengungkapkan bahwa penerapan standarisasi data memberikan pengaruh signifikan terhadap kinerja model. Model yang dilatih tanpa standarisasi mengalami penurunan akurasi hingga 2% serta penurunan nilai macro-F1 sebesar 0,02, yang menegaskan pentingnya konsistensi skala data masukan selama proses pelatihan.

Tabel 1. Perbandingan Kinerja Konfigurasi ANN untuk Klasifikasi Gaya Belajar.

ID	Layers	Activation	Std	λ	Iter	F1-Aud	F1-Kin	F1-Vis	Macro-F1	Acc (%)
A1	1L(32)	ReLU	Y	1×10^{-4}	1000	0.931	0.896	0.847	0.891	90.5
A2	2L(16,16)	ReLU	Y	1×10^{-3}	1000	0.925	0.892	0.867	0.895	90.5
A3	2L(32,32)	Tanh	Y	1×10^{-3}	1000	0.943	0.923	0.841	0.902	91.5
B1	2L(64,32)	ReLU	Y	1×10^{-3}	1000	0.931	0.908	0.867	0.902	91.2
B2	3L(64,64,16)	ReLU	Y	1×10^{-3}	1000	0.928	0.895	0.857	0.893	90.5
B3	2L(64,32)	ReLU	N	1×10^{-3}	1000	0.928	0.900	0.810	0.883	89.8

	2)			10^{-3}	0	28	8	2		
B4	2L(64,3	ReLU	Y	$1 \times$	100	0.9	0.93	0.85	0.908	91.9
	2)			10^{-2}	0	37	7	0		
C1	2L(64,3	ReLU	Y	$1 \times$	500	0.9	0.93	0.85	0.908	91.9
	2)			10^{-2}		37	7	0		
C2	2L(64,3	ReLU	Y	$1 \times$	200	0.9	0.93	0.85	0.908	91.9
	2)			10^{-2}	0	37	7	0		

Pengaruh Arsitektur Jaringan terhadap Kinerja Model

Jumlah lapisan tersembunyi dan jumlah neuron terbukti berpengaruh signifikan terhadap kemampuan Artificial Neural Network (ANN) dalam merepresentasikan pola gaya belajar yang kompleks. Berdasarkan hasil pada Tabel I, model dengan satu lapisan tersembunyi (A1) mencapai akurasi sebesar 0,905. Peningkatan arsitektur menjadi dua lapisan tersembunyi dengan jumlah neuron moderat (A3: 32–32) mampu meningkatkan kinerja model secara konsisten hingga mencapai akurasi 0,915 dan nilai macro-F1 yang lebih tinggi. Hal ini menunjukkan bahwa penggunaan dua lapisan tersembunyi memungkinkan ANN mengekstraksi representasi fitur yang lebih abstrak dari data perilaku mahasiswa.

Sebaliknya, penambahan lapisan tersembunyi ketiga pada konfigurasi B2 (64–64–16) tidak memberikan peningkatan kinerja yang signifikan. Model B2 justru mengalami penurunan performa dengan akurasi sebesar 0,905, sebagaimana ditunjukkan pada Tabel I. Temuan ini mengindikasikan bahwa peningkatan kedalaman jaringan yang berlebihan berpotensi menyebabkan *overfitting*, terutama pada dataset berukuran menengah dengan jumlah 1.419 sampel. Dengan demikian, arsitektur ANN dengan dua lapisan tersembunyi (A3) memberikan keseimbangan terbaik antara kapasitas pembelajaran dan kemampuan generalisasi model.

Pengaruh Parameter ANN terhadap Kinerja Model

1) Fungsi Aktivasi

Dua fungsi aktivasi, yaitu ReLU dan Tanh, diuji dalam penelitian ini. Meskipun keduanya menghasilkan kinerja rata-rata yang relatif sebanding (macro-F1 $\approx$ 0,90), model berbasis ReLU menunjukkan kurva pembelajaran yang lebih stabil serta konvergensi yang lebih cepat. Temuan ini sejalan dengan hasil penelitian sebelumnya yang menyatakan bahwa ReLU mampu mengurangi permasalahan *vanishing gradient* yang umum terjadi pada jaringan dengan kedalaman lebih besar.

2) Standarisasi Data

Standarisasi data berperan penting dalam meningkatkan stabilitas proses pelatihan. Perbandingan antara model B1 (input terstandarisasi) dan B3 (tanpa standarisasi) menunjukkan penurunan akurasi dari 0,912 menjadi 0,898, serta penurunan nilai macro-F1

dari 0,902 menjadi 0,883 ketika standarisasi tidak diterapkan. Penurunan kinerja terbesar terjadi pada kelas Visual, dengan nilai F1-score menurun dari 0,867 menjadi 0,812, yang mengindikasikan bahwa ketidakkonsistenan skala fitur berdampak negatif terhadap proses pembelajaran model.

3) Regularisasi (λ)

Regularisasi terbukti berperan krusial dalam menjaga stabilitas model dan mencegah overfitting. Peningkatan koefisien regularisasi dari 1×10^{-3} menjadi 1×10^{-2} mampu meningkatkan akurasi dari 0,912 menjadi 0,919, serta nilai macro-F1 dari 0,902 menjadi 0,908. Peningkatan paling signifikan terjadi pada kelas Kinestetik, dengan nilai F1-score meningkat dari 0,908 menjadi 0,937. Hasil ini mendukung temuan penelitian sebelumnya yang menyatakan bahwa regularisasi yang disetel dengan baik dapat meningkatkan kemampuan generalisasi dan mengurangi variansi model.

4) Jumlah Iterasi Pelatihan


Eksperimen dengan 500, 1000, dan 2000 epoch menunjukkan perbedaan kinerja yang tidak signifikan, di mana seluruh konfigurasi mencapai akurasi sebesar 0,919. Hal ini mengindikasikan bahwa model telah mencapai konvergensi optimal sebelum 500 epoch, sehingga konfigurasi yang diusulkan bersifat efisien. Penambahan jumlah iterasi setelah titik tersebut hanya meningkatkan biaya komputasi tanpa memberikan peningkatan kinerja yang berarti.

Analisis Kinerja Berdasarkan Kelas

Analisis kinerja per kelas menunjukkan bahwa Artificial Neural Network (ANN) mampu menangkap karakteristik perilaku yang membedakan masing-masing gaya belajar secara efektif. Kelas Auditori dan Kinestetik secara konsisten memperoleh nilai F1-score yang lebih tinggi, masing-masing sebesar 0,93 dan 0,91, sementara kelas Visual menunjukkan nilai yang relatif lebih rendah (0,85). Perbedaan ini disebabkan oleh adanya tumpang tindih karakteristik antara gaya belajar Visual dengan dua kategori lainnya, sehingga proses klasifikasinya menjadi lebih menantang.

Meskipun demikian, selisih kinerja antar kelas yang relatif kecil ($\Delta F < 0,1$) menunjukkan bahwa model mempertahankan performa yang seimbang, sebagaimana tercermin dari nilai macro-F1 yang tinggi ($> 0,90$). Berdasarkan Tabel 1, konfigurasi B4 dua lapisan tersembunyi (64–32 neuron), input terstandarisasi, aktivasi ReLU, dan regularisasi $\lambda = 1 \times 10^{-2}$ menunjukkan konsistensi kinerja terbaik pada tingkat kelas, dengan kelas Kinestetik

memiliki daya diskriminasi paling kuat. Gambar 1 menampilkan kurva ROC untuk masing-masing kelas.



Gambar 1. Kurva ROC untuk konfigurasi ANN dengan kinerja terbaik (B4) menggunakan evaluasi one-vs-rest.

Evaluasi lanjutan menggunakan analisis ROC one-vs-rest pada model B4 memperlihatkan nilai AUC yang tinggi untuk seluruh kelas, yaitu 0,9781 (Auditori), 0,9849 (Kinestetik), dan 0,9793 (Visual), dengan macro-AUC $\approx$ 0,9808. Hasil ini menegaskan bahwa ANN teroptimasi tidak hanya menghasilkan keputusan klasifikasi yang akurat, tetapi juga keluaran probabilitas yang terkalibrasi dengan baik, sehingga meningkatkan keandalan sistem dalam mendukung personalisasi pembelajaran adaptif.

Konfigurasi Model Optimal

Di antara seluruh konfigurasi yang diuji, Model B4—ANN dengan dua lapisan tersembunyi (64 dan 32 neuron), fungsi aktivasi ReLU, regularisasi $\lambda = 1 \times 10^{-2}$, dan input terstandarisasi—menunjukkan kinerja paling optimal. Model ini secara konsisten mencapai akurasi 0,919 dan macro-F1 sebesar 0,908, dengan variasi kinerja antar percobaan di bawah 2%. Konfigurasi ini memberikan kemampuan generalisasi yang baik, mengurangi *overfitting*, serta menghasilkan konvergensi yang efisien. Oleh karena itu, model B4 sesuai untuk diterapkan dalam sistem pembelajaran adaptif guna mendukung penyesuaian materi pembelajaran berdasarkan profil gaya belajar mahasiswa secara otomatis.

Pembahasan dan Implikasi

Hasil penelitian ini menegaskan bahwa optimasi jaringan secara signifikan meningkatkan kinerja klasifikasi gaya belajar berbasis Artificial Neural Network (ANN). Tiga

faktor utama yang berpengaruh terhadap stabilitas model adalah standarisasi data, regularisasi yang tepat, dan kesederhanaan arsitektur jaringan. Jaringan dengan kedalaman yang lebih besar tidak selalu memberikan peningkatan kinerja, khususnya pada dataset pendidikan berskala menengah.

Dari sisi pedagogis, model yang diusulkan berpotensi diterapkan sebagai dasar pengembangan Intelligent Tutoring Systems (ITS) dan sistem *e-learning* adaptif untuk mengidentifikasi preferensi belajar mahasiswa secara *real-time*. Ke depan, pengembangan model dapat diarahkan pada arsitektur hibrida, seperti CNN atau LSTM, serta penerapan pendekatan Explainable AI (XAI) guna meningkatkan interpretabilitas keputusan model.

Meskipun konfigurasi B4 menunjukkan kemampuan diskriminasi antarkelas yang tinggi berdasarkan nilai AUC, hasil ini belum menjelaskan kontribusi fitur pada tingkat butir kuesioner. Oleh karena itu, analisis berbasis interpretabilitas, seperti SHAP atau LIME, diperlukan pada penelitian selanjutnya untuk mengidentifikasi faktor dominan yang memengaruhi masing-masing kategori gaya belajar, sehingga mendukung pengambilan keputusan pedagogis yang lebih tepat.

5. KESIMPULAN DAN SARAN

Penelitian ini menyajikan konfigurasi Artificial Neural Network (ANN) teroptimasi untuk klasifikasi gaya belajar berdasarkan model VAK. Hasil eksperimen pada berbagai variasi arsitektur dan parameter pelatihan menunjukkan bahwa penerapan regularisasi ($\lambda = 1 \times 10^{-2}$) dan standarisasi input berperan penting dalam meningkatkan stabilitas model. Konfigurasi terbaik, yaitu ANN dengan dua lapisan tersembunyi (64–32 neuron) dan fungsi aktivasi ReLU, mencapai akurasi sebesar 91,9% dan nilai macro-F1 sebesar 0,908.

Analisis ROC selanjutnya mengonfirmasi keandalan daya diskriminasi konfigurasi tersebut dengan nilai macro-AUC sekitar 0,981, yang menunjukkan keluaran probabilitas yang terkalibrasi dengan baik pada seluruh kelas. Secara keseluruhan, temuan ini menegaskan bahwa pemilihan arsitektur dan regularisasi yang tepat secara signifikan meningkatkan ketangguhan ANN, sehingga pendekatan yang diusulkan layak dijadikan dasar pengembangan sistem pembelajaran adaptif. Penelitian selanjutnya akan mengintegrasikan metode berbasis interpretabilitas, seperti SHAP, untuk mengidentifikasi dominasi fitur pada tingkat atribut serta memperluas validasi model pada dataset multi-institusi yang lebih beragam.

DAFTAR REFERENSI

- Al-Badarenah, A., & Alsakran, J. (2020). An automated learning style detection method using neural networks. *International Journal of Advanced Computer Science and Applications*, 11(1), 1–8. <https://doi.org/10.14569/IJACSA.2020.0110101>
- Andari, E. (2022). Implementasi kurikulum Merdeka Belajar menggunakan learning management system (LMS). *Allimna: Jurnal Pendidikan Profesi Guru*, 1(2), 65–79. <https://doi.org/10.30762/allimna.v1i2.694>
- Bai, Y., Yang, E., Han, B., Yang, Y., Li, J., Mao, Y., Niu, G., & Liu, T. (2021). Understanding and improving early stopping for learning with noisy labels. *Neurocomputing*. <https://doi.org/10.48550/arXiv.2106.15853>
- Castillo, A., Morales, R., & Perez, J. (2020). Learning style classification using artificial neural networks. In *Proceedings of the IEEE Global Engineering Education Conference (EDUCON)* (pp. 1–6). <https://doi.org/10.1109/EDUCON45650.2020.9125166>
- Chen, C. M., & Li, Y. L. (2020). Personalized e-learning system based on learner's learning style. *Computers & Education*, 146, 103771. <https://doi.org/10.1016/j.compedu.2009.08.021>
- Drachslar, H., & Greller, W. (2020). Privacy and analytics – It's a DELICATE issue. In *Proceedings of the 10th International Conference on Learning Analytics & Knowledge* (pp. 89–98). <https://doi.org/10.1145/3375462.3375503>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. <https://doi.org/10.7551/mitpress/10243.001.0001>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. <https://doi.org/10.1109/ICCV.2015.123>
- Hinojosa Lee, M. C., Braet, J., & Springael, J. (2024). Performance metrics for multilabel emotion classification: Comparing micro, macro, and weighted F1-scores. *Applied Sciences*, 14(21), 9863. <https://doi.org/10.3390/app14219863>
- Huang, S., Fang, N., & Fang, X. (2021). Student learning behavior modeling using learning analytics. *IEEE Access*, 9, 138248–138258. <https://doi.org/10.1109/ACCESS.2021.3052679>
- Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *Proceedings of the International Conference on Machine Learning* (pp. 448–456). <https://doi.org/10.48550/arXiv.1502.03167>
- Karamouzis, S., & Vrettaros, J. (2021). Learning style classification using machine learning algorithms. *Education and Information Technologies*, 26(3), 3435–3456. <https://doi.org/10.1007/s10639-020-10404-9>
- Kim, Y. S., Kim, M. K., Fu, N., Liu, J., Wang, J., & Srebric, J. (2024). Investigating the impact of data normalization methods on predicting electricity consumption using artificial neural networks. *Sustainable Cities and Society*. <https://doi.org/10.1016/j.scs.2024.105570>
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. In *Proceedings of the International Conference on Learning Representations*. <https://doi.org/10.48550/arXiv.1412.6980>
- Knoll, A. R., Otani, H., Skeel, R. L., & Van Horn, K. R. (2021). Learning style, judgments, and performance. *Educational Psychology*, 41(2), 1–15. <https://doi.org/10.1080/01443410.2020.1830848>
- Li, Y., Chen, B., & Huang, R. (2021). Deep learning for adaptive learning systems: A survey. *IEEE Access*, 9, 157113–157130. <https://doi.org/10.1109/ACCESS.2021.3120125>

- Liao, S. H., Chu, P. H., & Hsiao, P. Y. (2012). Data mining techniques and applications – A decade review. *Expert Systems with Applications*, 39(12), 11303–11311. <https://doi.org/10.1016/j.eswa.2012.02.057>
- Papamitsiou, Z., & Economides, A. A. (2020). Learning analytics and educational data mining: Towards a framework for learning design. *Educational Technology & Society*, 23(1), 1–15.
- Rogowsky, B. A., Calhoun, B. M., & Tallal, P. (2020). Matching learning style to instructional method: Revisited. *Educational Psychology Review*, 32(3), 709–734. <https://doi.org/10.1007/s10648-019-09489-7>
- Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(3), e1355. <https://doi.org/10.1002/widm.1355>
- Shen, S., Huang, Z., Chen, Q., & Li, Y. (2024). A survey of knowledge tracing: Models, variants, and applications. *IEEE Transactions on Learning Technologies*, 17(1), 1–18. <https://doi.org/10.1109/TLT.2023.3332157>
- Siemens, G., Gašević, D., Dawson, S., & Baker, R. S. (2022). Learning analytics and educational data mining: Towards communication and collaboration. In *Proceedings of the 12th International Conference on Learning Analytics & Knowledge* (pp. 1–5). <https://doi.org/10.1145/3506860.3506863>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15, 1929–1958.
- Uddin, M. F., & Kar, A. K. (2020). Student learning style detection using artificial neural networks. In *Proceedings of the IEEE International Conference on Emerging Technologies (ICET)* (pp. 1–6). <https://doi.org/10.1109/ICET51153.2020.9276562>
- Viberg, O., Hatakka, M., Bälter, O., & Mavroudi, A. (2020). The current landscape of learning analytics in higher education. *Computers in Human Behavior*, 107, 105945. <https://doi.org/10.1016/j.chb.2019.105945>
- Wang, S., Liu, Y., & Chen, H. (2025). Large language models for education: A survey and outlook. *IEEE Access*, 13, 1421–1445. <https://doi.org/10.1109/ACCESS.2024.3509217>
- Xu, H., Zhang, Y., & Li, X. (2024). Large language models for education: A survey. *IEEE Access*, 12, 55910–55936. <https://doi.org/10.1109/ACCESS.2024.3387261>
- Zanellati, A., Di Mitri, D., Gabbrielli, M., & Levrini, O. (2024). Hybrid models for knowledge tracing: A systematic literature review. *IEEE Transactions on Learning Technologies*, 17(2), 210–225. <https://doi.org/10.1109/TLT.2023.3341129>
- Zhang, H., Huang, T., Liu, S., et al. (2020). Learning style classification using deep neural networks. *Journal of Cloud Computing*, 9, 26. <https://doi.org/10.1186/s13677-020-00165-y>