

## Rekomendasi Paket Mata Pelajaran SMA Kurikulum Merdeka Menggunakan Algoritma Backpropagation

Eri Subiyanto<sup>\*1</sup>, Handaru Jati<sup>2</sup>

<sup>1</sup>Fakultas Teknik, Pendidikan Teknik Elektronika dan Informatika, Universitas Negeri Yogyakarta,  
Yogyakarta, Indonesia

Email: <sup>1</sup>[eri.subiy@gmail.com](mailto:eri.subiy@gmail.com), <sup>2</sup>[handaru@uny.ac.id](mailto:handaru@uny.ac.id)

### Abstrak

Pemahaman tentang potensi diri, yang meliputi bakat, minat, dan kemampuan bagi setiap siswa merupakan kunci keberhasilan dalam meniti karier masa depan. Pada kenyataannya, hubungan antara bakat, minat dan kemampuan sangatlah kompleks, yang sangat sulit diselesaikan dengan menggunakan aturan-aturan pemrograman sederhana (*rule-based system*). Penelitian ini mengembangkan rekomendasi paket mata pelajaran pilihan bagi siswa Sekolah Menengah Atas (SMA) sesuai dengan kebijakan pemerintah yang tertuang dalam kurikulum merdeka yaitu sekolah mengorganisasikan 9 mata pelajaran pilihan ke dalam 4 kelompok peminatan (paket). Algoritma *Backpropagation* diimplementasikan dalam penelitian ini karena efektivitasnya dalam memproses pola data kompleks melalui mekanisme pembelajaran adaptif untuk menghasilkan rekomendasi paket mata pelajaran yang akurat bagi siswa. Model ini mengintegrasikan 13 variabel input yang mencakup nilai tes diagnostik pada 9 mata pelajaran pilihan sebagai representasi bakat, serta 4 paket pilihan sebagai representasi minat siswa. Adapun output yang dihasilkan berupa klasifikasi 4 paket mata pelajaran berdasarkan capaian prestasi akademik selama masa pembelajaran. Arsitektur jaringan saraf tiruan yang dikembangkan menggunakan konfigurasi 13-13-4, yang terdiri dari 13 neuron pada *input layer*, 13 neuron pada *hidden layer*, dan 4 neuron pada *output layer* sebagai representasi pilihan paket. Pembagian data strategis berbasis domain atau *transfer learning* pada model diterapkan untuk mempertahankan akurasi personalisasi rekomendasi yang tangguh terhadap karakteristik lintas angkatan. Rekomendasi berupa paket mata pelajaran pilihan dihasilkan melalui proses training pada data pelatihan (*source domain*). Dengan melakukan modifikasi parameter bobot secara berulang yang bertujuan untuk meminimalisir kesalahan yaitu *Mean Square Error (MSE)* antara nilai aktual dengan nilai prediksi. Pengamatan terhadap grafik nilai MSE dilakukan pada setiap modifikasi parameter, sampai dengan diperoleh fenomena grafik MSE yang mengalami penurunan secara signifikan (konvergen). Hasil validasi pada data pengujian (*target domain*) menunjukkan bahwa kinerja model yang dikembangkan adalah sangat memuaskan. *Accuracy* mencapai 91,52%, menunjukkan bahwa *output* yang dihasilkan model adalah benar. *Precision* sebesar 99,71% menunjukkan tingkat kesalahan yang sangat rendah dalam mengidentifikasi paket mata pelajaran yang relevan. Selain itu, nilai *recall* sebesar 91,72%, dan *F1-score* sebesar 95,55% semakin menegaskan keandalan dan efektivitas model dalam memberikan rekomendasi yang akurat dan relevan. Tingginya nilai efektivitas pada seluruh metrik evaluasi membuktikan bahwa pembelajaran adaptif pada *Backpropagation* mampu menangani pola data pendidikan yang kompleks secara akurat. Penelitian ini memberikan kontribusi praktis dalam membantu siswa menentukan pilihan paket mata pelajaran yang selaras dengan potensi diri, yang secara jangka panjang diproyeksikan dapat meningkatkan kesiapan siswa dalam meniti karier masa depan.

**Kata Kunci:** *backpropagation, kurikulum merdeka, mata pelajaran pilihan*

### *Recommended High School Subject Packages Based on the Independent Curriculum Using the Backpropagation Method*

#### *Abstract*

*Understanding each student's potential, including talents, interests, and abilities, is key to success in pursuing a future career. In reality, the relationship between talents, interests, and abilities is complex and difficult to resolve using simple programming rules (rule-based systems). This study develops recommendations for elective subject packages for high school students in accordance with government policy outlined in the independent curriculum, which requires schools to organize 9 elective subjects into 4 interest groups (packages). The Backpropagation algorithm was implemented in this study due to its effectiveness in processing complex data patterns through an adaptive learning mechanism, thereby generating accurate subject package*

recommendations for students. This model integrates 13 input variables, including diagnostic test scores for 9 elective subjects as a proxy for talent and 4 elective packages as a proxy for student interests. The resulting output is a classification of 4 subject packages based on academic achievement during the learning period. The developed artificial neural network architecture uses a 13-13-4 configuration, consisting of 13 neurons in the input layer, 13 in the hidden layer, and 4 in the output layer, to represent package choices. Domain-based strategic data sharing or transfer learning in the model is applied to maintain the accuracy of personalized recommendations that are robust to cross-generation characteristics. Recommendations in the form of selected subject packages are generated through a training process on the training data (source domain). By repeatedly adjusting the weight parameters, the aim is to minimize the Mean Squared Error (MSE) between the actual and predicted values. Observations of the MSE graph are carried out for each parameter modification until the MSE graph shows a significant decrease (convergence). Validation results on the test data (target domain) indicate that the developed model's performance is very satisfactory. The accuracy reaches 91,52%, indicating that the model's output is correct. Precision of 99,71% indicates a very low error rate in identifying relevant subject packages. In addition, the recall of 91,72% and the F1-score of 95,55% further confirm the model's reliability and effectiveness in providing accurate and relevant recommendations. The high effectiveness value across all evaluation metrics demonstrates that adaptive learning in Backpropagation can accurately handle complex educational data patterns. This research provides a practical contribution in helping students choose a course package that aligns with their potential, which is projected to improve their long-term readiness for future careers.

**Keywords:** backpropagation, independent curriculum, elective subjects

## 1. PENDAHULUAN

Kurikulum Merdeka telah menciptakan era baru dalam pendidikan di Indonesia, membawa semangat fleksibilitas dan personalisasi dalam proses belajar. “Di jenjang SMA, Kurikulum Merdeka memberikan peserta didik keleluasaan untuk memilih mata pelajaran sesuai dengan minat, bakat, dan kemampuannya” [1]. Dengan memilih mata pelajaran sesuai dengan motivasi dirinya (minat, bakat dan kemampuan), maka siswa dapat mengeksplorasi karier secara lebih mendalam sebagai upaya mencapai kesuksesan karir di masa depan. Namun sebaliknya, kurangnya pengetahuan mengenai kemampuan (prestasi), minat, serta bakat individu menjadi penghalang utama bagi mereka. Kondisi demikian cenderung mengarah kepada fenomena bahwa pemilihan mata pelajaran hanya karena mengikuti teman atau sebatas tebakan. Banyak dari siswa yang belum sepenuhnya memahami potensi diri, sehingga kesulitan dalam menentukan mata pelajaran pilihan yang tepat. Tahun 2024 Puslapdik kementerian pendidikan mengungkapkan bahwa sebanyak 87% mahasiswa di Indonesia merasa salah jurusan, salah satu faktornya adalah kurang mengenali bakat dan minat [2].

Kenyataannya, hubungan antara bakat, minat dan kemampuan (prestasi) merupakan hubungan yang kompleks karena saling mempengaruhi. Sesuai dengan regulasi Kurikulum Merdeka, satuan pendidikan diwajibkan menyelenggarakan minimal 7 dari 13 mata pelajaran pilihan yang tersedia. Implementasi kebijakan ini dilakukan melalui pengorganisasian mata pelajaran ke dalam kelompok atau paket tertentu, yang diselaraskan dengan ketersediaan sumber daya serta daya dukung masing-masing sekolah. Setiap mata pelajaran yang disediakan oleh satuan pendidikan bukan sekedar variabel yang berdiri sendiri, melainkan saling terkait dan saling mempengaruhi, mencakup spektrum luas dari mata pelajaran pilihan yang telah diselesaikan oleh siswa pada fase E atau kelas X (sepuluh). Mata pelajaran pilihan yang bermacam-macam tersebut menjadi sangat sulit untuk diselesaikan dengan menggunakan aturan-aturan pemrograman sederhana (*rule-based system*). Aturan-aturan yang demikian hanya akan menghasilkan korelasi yang lebih rendah dibandingkan dengan algoritma pembelajaran mesin [3]. Penerapan *if-then* (kondisi bersyarat), penjumlahan (*sum*) diikuti pengurutan (*sort*) akan sangat rentan terhadap *error*, kehilangan data, atau kesalahan logika (*if-then*). Selain itu, juga cenderung mengabaikan interaksi antar variabel dalam memberikan rekomendasi mata pelajaran pilihan yang sesuai dengan potensi siswa.

Kompleksitas tersebut juga berpengaruh pada kualitas paket mata pelajaran pilihan pada jenjang tertentu. Paket mata pelajaran yang dihasilkan harus relevan bagi satuan pendidikan berdasarkan karakteristik historis antar jenjang. Oleh karena itu, penelitian ini mengintegrasikan konsep *Transfer Learning* dalam skema pelatihan model. Dengan mengaplikasikan pengetahuan yang terdapat pada satu domain (*source domain*) pada domain lain yang terkait namun berbeda (*target domain*) untuk meningkatkan performa generalisasi [4]. Dalam konteks ini, model dilatih menggunakan data historis yang lebih kompleks dari siswa tingkat akhir (Kelas XII) untuk mengekstraksi fitur-fitur akademik fundamental, yang kemudian ditransfer untuk memvalidasi dan memprediksi kebutuhan siswa pada jenjang di bawahnya (Kelas XI).

Rekomendasi pada bidang pendidikan merupakan alat yang menyaring informasi berdasarkan relevansi setiap peserta didik dalam rangka memberikan rekomendasi yang dipersonalisasi [5]. Personalisasi rekomendasi dapat dicapai melalui analisis umpan balik dan kinerja historis peserta didik yang telah ditempuh melalui proses pembelajaran. Analisis tersebut digunakan untuk memprediksi dan menyarankan materi pelajaran di masa yang akan datang [6]. Oleh karena itu rekomendasi personal ini sangat krusial dalam mendukung implementasi kebijakan kurikulum Merdeka yang menuntut penentuan mata pelajaran pilihan yang sesuai dengan bakat, minat, dan kemampuan (prestasi) siswa sebagai pedoman dalam merencanakan rencana karier di masa yang akan datang. Bakat, minat, dan kemampuan siswa merupakan atribut atau kategori yang berbeda, sehingga dapat dimodelkan sebagai klasifikasi multilabel. Setiap atribut data diberi label yang merupakan perluasan dari klasifikasi tunggal [7]. Dalam skenario ini, sistem berupaya memprediksi semua label (kategori/atribut) yang mungkin berlaku untuk suatu item bagi pengguna tertentu, atau sebaliknya, memprediksi item yang paling sesuai dengan kombinasi label yang diminati pengguna. Dengan demikian, klasifikasi multilabel menyediakan kerangka kerja yang kuat untuk meningkatkan granularitas dan relevansi rekomendasi yang disajikan dalam bentuk daftar item sehingga memberikan rekomendasi dengan akurasi tinggi yang dapat membantu peserta didik menemukan materi pelajaran yang sesuai dengan minat dan kebutuhan mereka [8].

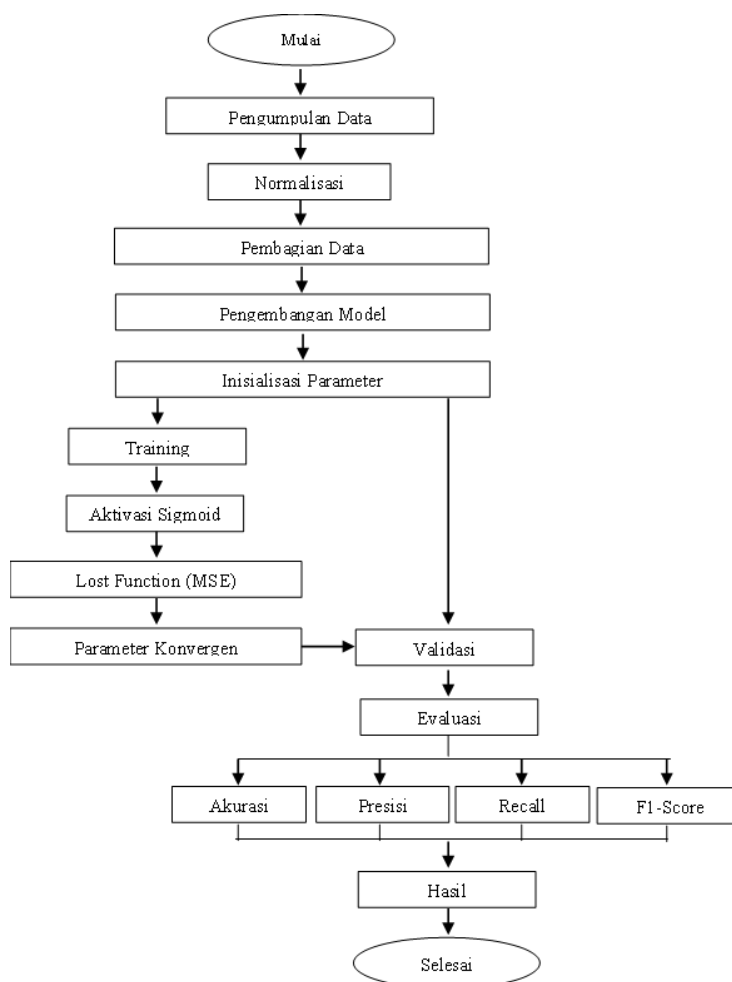
Penggunaan algoritma *backpropagation* dengan prosedur yang umum dan relatif sederhana telah terbukti efektif untuk membangun representasi yang tepat. Hasil yang representatif dapat diperoleh melalui penyesuaian bobot yang dilakukan secara berulang untuk meminimalkan *error (MSE)* antara nilai prediksi dengan nilai sebenarnya [9]. Semakin kecil nilai *error* yang dihasilkan menunjukkan bahwa hasil yang diperoleh adalah akurat. Penerapan algoritma *backpropagation* dengan fungsi aktivasi *sigmoid* menghasilkan akurasi yang tinggi dalam menyelesaikan hubungan yang kompleks untuk melakukan generalisasi pada permasalahan klasifikasi multilabel [10] [11]. Kinerja model ini kemudian dievaluasi terhadap hasil klasifikasi tersebut menggunakan metrik evaluasi yaitu *accuracy, precision, recall dan f1-score* [12].

Penelitian ini bertujuan untuk menganalisis dan mengevaluasi penerapan algoritma *backpropagation* dalam memberikan rekomendasi paket mata pelajaran bagi siswa SMA. Kebaruan penelitian ini terletak pada integrasi strategi *transfer learning*, di mana model dilatih menggunakan data historis Kelas XII untuk mengekstraksi fitur akademik fundamental yang kemudian diaplikasikan pada siswa Kelas XI. Pendekatan ini dilakukan untuk menjamin ketangguhan (*reliability*) sistem rekomendasi lintas jenjang dalam ekosistem Kurikulum Merdeka yang dinamis. Implementasi model dilakukan menggunakan bahasa pemrograman *Python* untuk memproses data potensi siswa sebagai indikator kompleks yang saling mempengaruhi.

## 2. METODE PENELITIAN

Penelitian ini terdiri atas 2 (dua) tahapan yang utama yaitu tahap pelatihan (*training*) dan validasi. Metodologi yang diterapkan menggunakan pendekatan Domain Adaptation dengan memanfaatkan hierarki historis akademis melalui mekanisme adaptasi kontekstual yang selaras dengan struktur data sekolah. Data nilai, bakat, dan minat siswa kelas XII diposisikan sebagai *source domain (training set)*, data siswa kelas XI berfungsi sebagai *target domain (test set)*. Strategi ini dirancang untuk menguji ketangguhan model melalui skema *backward-generalization* dengan mengevaluasi sejauh mana fitur prediktor yang diekstraksi dari tingkat kognitif kompleks (Kelas 12) tetap konsisten dan relevan saat diaplikasikan pada tingkat fundamental (Kelas 11). Pendekatan ini sangat relevan dengan implementasi Kurikulum Merdeka, khususnya pada Fase F (Kelas 11 dan 12), di mana kesinambungan capaian pembelajaran sangat ditekankan. Dengan memvalidasi pola keberhasilan dari tingkat lanjut ke tingkat dasar, penelitian ini mendukung prinsip pembelajaran berdiferensiasi melalui penyediaan basis data prediktif yang presisi.

Tahap pelatihan (*training*) dilakukan untuk mencari *Mean Square Error (MSE)* terendah antara nilai yang dihasilkan (aktual) dengan nilai solusi (prediksi). Pelatihan dilakukan secara berulang sehingga diperoleh nilai bobot dan bias pada *input layer, hidden layer* dan *output layer* yang paling optimal berdasarkan nilai *MSE* terendah [13]. Nilai *MSE* yang lebih rendah menunjukkan akurasi dan reliabilitas yang tinggi dalam menghasilkan prediksi [14]. Tahap validasi sangat penting untuk dilaksanakan untuk melakukan evaluasi terhadap kinerja model agar mendapatkan hasil yang lebih optimal. Evaluasi kinerja model diukur dengan menerapkan matrik evaluasi yaitu *accuracy, precision, recall dan f1-score* [15]. Detail tahapan dari penelitian ditunjukkan pada gambar 1.



Gambar 1. Tahapan Penelitian

### 2.1 Pengumpulan Data

Data diperoleh dengan mengambil dokumentasi sekolah yaitu teknik pengumpulan data dengan yang bersumber dari dokumen [16]. Data yang digunakan mencakup variabel-variabel yang merepresentasikan bakat, minat, dan capaian akademik siswa, yang dirinci sebagai berikut :

#### a. Data paket mata pelajaran

Satuan pendidikan menawarkan 9 mata pelajaran pilihan yang diorganisasikan ke dalam 4 (empat) paket utama. Setiap paket disusun untuk mengakomodasi kecenderungan minat akademik siswa sebagai berikut:

- Paket 1 : Matematika Tingkat Lanjut, Biologi, Fisika, Kimia
- Paket 2 : Sosiologi, Geografi, Ekonomi, Informatika
- Paket 3 : Kimia, Bahasa Inggris Tingkat Lanjut, Biologi, Ekonomi
- Paket 4 : Matematika, Fisika, Bahasa Inggris Tingkat Lanjut, Matematika Tingkat Lanjut

#### b. Data nilai siswa kelas XI dan siswa kelas XII yang masing-masing terdiri dari :

Penelitian ini menggunakan data dari dua kohort, yaitu siswa Kelas XI dan siswa Kelas XII, yang mencakup komponen berikut:

1. Nilai rapor semester 1 dan 2, digunakan sebagai representasi capaian prestasi akademik berkelanjutan.
2. Nilai tes diagnostik, digunakan sebagai representasi bakat dan kesiapan kognitif siswa terhadap mata pelajaran tertentu.
3. Hasil angket, digunakan sebagai data pendukung untuk mengidentifikasi preferensi minat siswa terhadap paket yang tersedia.

### 2.2 Normalisasi Data

Normalisasi digunakan untuk merubah data ke dalam skala yang sama sehingga model *machine learning* lebih efektif dalam melakukan pembelajaran dengan mengkonversikan data ke dalam rentang nilai 0 – 1 [17]. Proses ini sangat penting dalam algoritma backpropagation untuk mencegah dominasi variabel dengan skala besar terhadap variabel berskala kecil serta mempercepat konvergensi model. Persamaan yang digunakan untuk transformasi ini adalah Min-Max Normalization sebagai berikut :


$$x_{normalized}^{(i)} = \frac{x^{(i)} - \min(x)}{\max(x) - \min(x)} \quad (1)$$

### 2.3 Pembagian Data

Penelitian ini menerapkan skema pembagian data strategis berbasis domain, yaitu 285 data siswa Kelas XII dialokasikan sebagai *Source Domain* (set pelatihan) dan 283 data siswa Kelas XI diposisikan sebagai *Target Domain* (set pengujian) untuk memvalidasi performa model. Skema pembagian lintas kohort ini bertujuan untuk mempertahankan ketangguhan (*robustness*) model pada distribusi data yang berbeda. Melalui pendekatan *temporal validation* ini, model diharapkan mampu memprediksi kebutuhan akademik di masa depan berdasarkan representasi fitur yang dipelajari dari data historis masa lalu melalui personalisasi pengalaman belajar [18]. Dalam konteks Kurikulum Merdeka, model harus mampu beradaptasi dengan profil siswa baru tanpa mengalami penurunan performa yang signifikan akibat perbedaan karakteristik antar angkatan (*cohort effect*). Dengan menggunakan data Kelas XII sebagai basis pengetahuan, Penelitian ini secara eksplisit menguji kemampuan transfer pengetahuan model terhadap data yang belum pernah dilihat sebelumnya (*unseen data*) pada jenjang Kelas XI [19] [20].

### 2.4 Pengembangan Model

*Backpropagation* merupakan model pembelajaran terawasi (*supervised learning*) yang digunakan untuk melakukan prediksi terhadap nilai tertentu berdasarkan target yang telah ditentukan [21]. Adapun yang menjadi target klasifikasi adalah paket mata pelajaran yang ditentukan berdasarkan akumulasi nilai rapor sebagai representasi kemampuan akademik siswa. Mekanisme ini bekerja dengan cara menghitung selisih (*error*) antara *output* prediksi dengan target aktual, kemudian mengalirkan balik sinyal kesalahan tersebut untuk memperbarui bobot pada setiap lapisan. Melalui proses iterasi yang berkelanjutan, model secara adaptif meminimalkan tingkat kesalahan sehingga mampu menghasilkan rekomendasi peminatan yang sangat akurat bagi setiap individu siswa.



Gambar 2. Arsitektur Jaringan

Dengan mengimplementasikan struktur jaringan saraf tiruan dengan konfigurasi 13-13-4, model dikembangkan secara spesifik untuk memetakan hubungan non-linear antara potensi siswa dengan paket mata pelajaran pilihan yang relevan. Komponen penyusun arsitektur tersebut adalah sebagai berikut:

- a. **Lapisan Input (Input Layer):** Terdiri dari 13 neuron ( $x_1$  hingga  $x_{13}$ ) yang merepresentasikan variabel input. Variabel ini mencakup nilai tes diagnostik pada mata pelajaran pilihan serta pilihan minat siswa ( $pil_1$  hingga  $pil_4$ ).
- b. **Lapisan Tersembunyi (Hidden Layer):** Menggunakan 13 neuron ( $z_1$  hingga  $z_{13}$ ) yang berfungsi untuk mengekstraksi fitur-fitur laten dari data input melalui fungsi aktivasi *Sigmoid*. Hubungan antara lapisan input dan lapisan tersembunyi dikelola oleh matriks bobot  $v_{ij}$  dan bias  $w_{jk}$ .
- c. **Lapisan Output (Output Layer):** Terdiri dari 4 neuron ( $y_1$  hingga  $y_4$ ) yang menggunakan fungsi aktivasi *Sigmoid* untuk menghasilkan probabilitas klasifikasi. Setiap neuron merepresentasikan paket pilihan mata pelajaran yang terdiri atas paket 1, paket 2, paket 3, dan paket 4.

### 2.5 Inisialisasi Parameter

Inisialisasi parameter merupakan tahap krusial untuk menentukan titik awal pencarian bobot optimal yang diindikasikan dengan penurunan gradien secara konsisten dengan memberikan nilai secara acak. Meskipun Pemberian parameter secara acak merupakan bentuk pendekatan yang paling sederhana dan sering digunakan [22] [23]. Penelitian ini menerapkan pendekatan yang lebih terukur yakni Xavier (Glorot) Normal Initialization. Metode ini dipilih untuk menjaga stabilitas varians sinyal di setiap lapisan jaringan guna menghindari kendala *vanishing gradient*. Bobot ( $W$ ) diinisialisasi mengikuti distribusi normal dengan rata-rata 0 dan varians ( $\sigma^2$ ) sebagai berikut [24]:

$$W \sim N\left(0, \frac{2}{n_{in} + n_{out}}\right) \tag{2}$$

Berdasarkan arsitektur 13-13-4, nilai varians yang ideal adalah :

$$\text{Lapisan input ke hidden } (n_{in} = 13, n_{out} = 13): \sigma^2 = \frac{2}{13+13} \approx 0,077 \tag{3}$$

$$\text{Lapisan hidden ke output } (n_{in} = 13, n_{out} = 4): \sigma^2 = \frac{2}{13+4} \approx 0,177 \tag{4}$$

Secara empiris, seluruh bobot awal ( $v_{ij}$  dan  $w_{jk}$ ) serta bias ( $v_0$  dan  $w_0$ ) diatur pada rentang nilai antara 0,1 hingga 0,9. Pemilihan rentang nilai bobot dan bias bertujuan untuk memastikan nilai masukan *neuron* berada pada zona linear fungsi *sigmoid* yang memiliki gradien tinggi. Hal ini krusial untuk menghindari fenomena *vanishing gradient* dan menjamin kelancaran pembaruan bobot selama proses iterasi berlangsung [25] [26]. Pendekatan ini terbukti secara eksperimental mampu mempercepat pencapaian titik konvergen dengan nilai MSE minimal [27]

### 2.6 Training, Aktivasi Sigmoid dan Cost Function (MSE)

*Training* merupakan proses pencarian parameter terbaik sehingga tercapai kondisi konvergen berdasarkan nilai MSE menggunakan data siswa kelas XII. Konvergen tercapai apabila grafik MSE menunjukkan fenomena penurunan secara konsisten dan tidak mengalami kenaikan yang signifikan [28]. Pencarian nilai *error* atau *MSE* terkecil diperoleh dengan cara melakukan modifikasi bobot dan bias secara berulang sehingga diperoleh bobot dan bias yang optimal [29]. Proses ini dilakukan secara sistematis yang terdiri atas beberapa tahapan, yaitu [30] [31]:

#### a. Inisialisasi parameter

Proses pembelajaran diawali dengan menetapkan inisialisasi parameter pada model jaringan. Bobot dan bias diberikan nilai awal secara acak terkendali dalam rentang 0,1 hingga 0,9. Selain itu, laju pembelajaran (*learning rate*) ditetapkan sebesar 0,1 dengan batasan iterasi maksimal sebanyak 100 *epoch*.

#### b. Perambatan maju

1. Setiap unit input menerima sinyal ( $x_i$ ) dan meneruskan ke semua unit pada lapisan tersembunyi
2. Setiap unit tersembunyi menjumlahkan ( $z_{ij}$ ) bobot sinyal input dengan persamaan sebagai berikut :

$$z_{in_j} = V_{0j} + \sum_{i=1}^n X_i V_{ij} \tag{5}$$

Dan menerapkan fungsi aktivasi sigmoid

$$Z_j = f(Z\_in_j) \tag{6}$$

3. Setiap unit output ( $y_k$ ) menjumlahkan bobot sinyal lapisan tersembunyi

$$y\_in_k = W_{0k} + \sum_{i=1}^p Z_i W_{jk} \tag{7}$$

Dan menerapkan fungsi aktivasi sigmoid

$$y_k = f(y\_in_k) \tag{8}$$

**c. Perambatan mundur**

1. Setiap unit output ( $Y_k$ ) menghitung error

$$\delta_k = (t_k - y_k)f(y\_in_k) \tag{9}$$

2. Koreksi bobot dengan persamaan sebagai berikut

$$\Delta W_{jk} = \alpha \delta_k Z_j \tag{10}$$

3. Koreksi bias dengan persamaan sebagai berikut

$$\Delta W_{0k} = \alpha \delta_k \tag{11}$$

4. setiap unit tersembunyi ( $Z_j$ ) menjumlahkan delta *input* (lapisan *output*)

$$\delta\_in_j = \sum_{k=1}^m \delta_k W_{jk} \tag{12}$$

5. Hitung error

$$\delta_j = \delta\_in_j f(Z\_in_j) \tag{13}$$

6. Hitung koreksi bobot

$$\Delta V_{jk} = \alpha \delta_j X_i \tag{14}$$

7. Hitung koreksi bias

$$\Delta V_{0j} = \alpha \delta_j \tag{15}$$

8. Perubahan Bobot dan Bias

$$W_{jk}(baru) = W_{jk}(lama) + \Delta W_{jk} \tag{16}$$

$$W_{ij}(baru) = V_{ij}(lama) + \Delta V_{ij} \tag{17}$$

9. Tes kondisi berhenti

Proses pencarian paramter berhenti jika kurva mse menunjukkan penurunan yang signifikan.

$$MSE = \frac{1}{n} \sum_{j=1}^n (y_j - a_j)^2 \tag{18}$$

**2.7 Validasi dan Evaluasi**

Evaluasi kinerja model dengan 4 rekomendasi yang dihasilkan yaitu dengan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* [32] [33]. Evaluasi menggunakan data siswa kelas XI sesuai dengan bobot dan bias yang diperoleh selama proses pelatihan.

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{19}$$

$$precision = \frac{TP}{TP+FN} \tag{20}$$

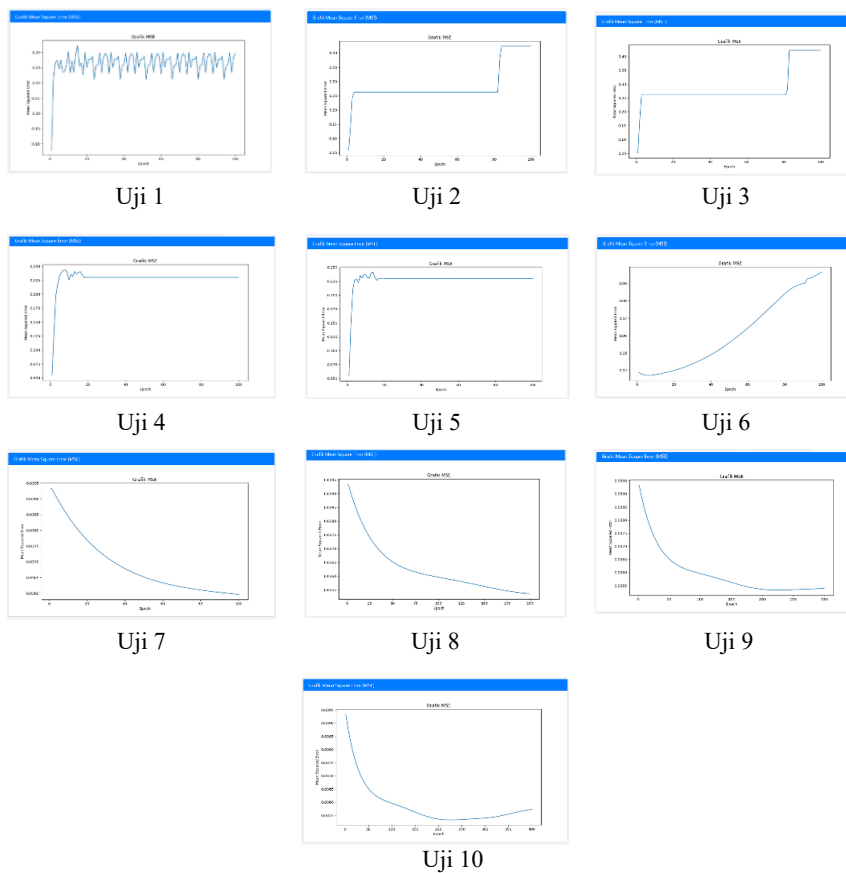
$$recall = \frac{TN}{TN+FP} \tag{21}$$

$$F1 - score = 2 \left( \frac{PPV+TPR}{PPV+TPR} \right) \tag{22}$$

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Training dan Lost Function (MSE)

Pencapaian kondisi konvergen dilakukan melalui optimasi hiperparameter untuk memastikan model mampu mengekstraksi pola data secara mendalam. Penentuan iterasi yang cukup tinggi akan memberikan ruang bagi algoritma *backpropagation* dalam meminimalkan nilai Mean Square Error (MSE) hingga mencapai titik stabil di bawah 0,01. Efektivitas dari konfigurasi hiperparameter yang telah ditetapkan dapat diamati melalui stabilitas penurunan nilai error selama proses pelatihan. Evaluasi dilakukan melalui sepuluh kali pengujian (Uji 1 hingga Uji 10) untuk memvalidasi konsistensi model dalam meminimalkan selisih antara prediksi dan target aktual. Gambar 3 menyajikan perbandingan grafik MSE dari seluruh rangkaian uji coba tersebut.



Gambar 3. Grafik MSE

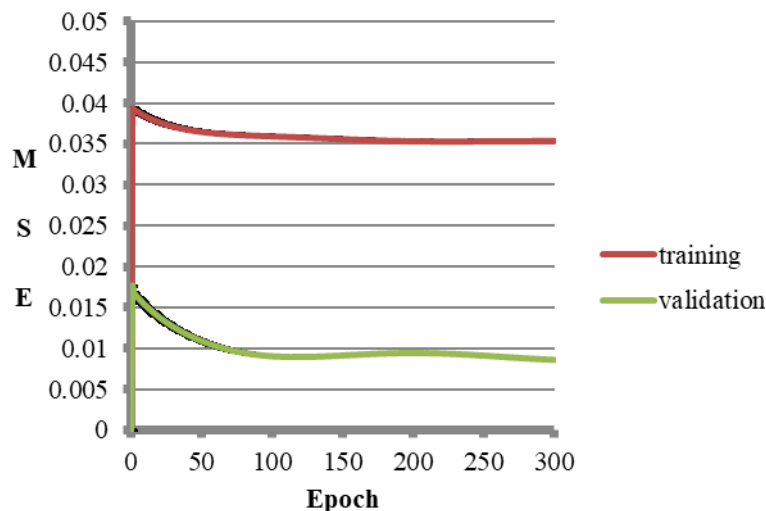
Pada beberapa pengujian awal (Uji 1 - Uji 6), model menunjukkan fluktuasi gradien yang signifikan, yang mengindikasikan adanya pencarian ruang bobot yang belum stabil. Namun, pada pengujian selanjutnya (Uji 7 - Uji 10), model berhasil menunjukkan tren penurunan MSE yang konsisten menuju titik konvergen di bawah ambang batas 0,01. Fenomena penurunan paling signifikan terlihat pada pengujian ke 9 dan ke 10 yang membuktikan bahwa mekanisme penyesuaian bobot secara adaptif mampu mengarahkan jaringan menuju titik minimum global sehingga berdampak pada peningkatan akurasi prediksi model terhadap data siswa. Kondisi

demikian telah mengindikasikan bahwa proses pelatihan (*training*) telah menghasilkan prediksi dengan tingkat kesalahan (*error*) paling kecil (konvergen).

Konvergensi yang dicapai dipertegas oleh grafik performa model yang mengilustrasikan proses konvergensi yang stabil baik pada fase pelatihan (*training*) maupun validasi (*validation*) yang disajikan data tabel 1.

Tabel 1. MSE pelatihan dan pengujian

Epoch	Training	Validasi
1	0.039333	0.017584
50	0.036518	0.010891
100	0.035963	0.009027
150	0.035628	0.009120
200	0.035362	0.009416
250	0.035347	0.009100
300	0.035402	0.008583



Gambar 4. Learning Curve

Berdasarkan Tabel 1, grafik Learning Curve pada Gambar 4 menunjukkan pergerakan nilai *Mean Squared Error* (MSE) yang terus menurun seiring bertambahnya jumlah *epoch*, baik pada fase pelatihan (*training*) maupun validasi. Pada awal iterasi (*epoch* 1), nilai MSE pelatihan berada di angka 0,039333 dan MSE validasi sebesar 0,017584. Seiring berjalannya proses hingga mencapai *epoch* 300, terlihat adanya konvergensi di mana nilai MSE pelatihan menyusut secara perlahan hingga menjadi 0,035402. Hal yang paling signifikan terlihat pada kurva validasi, di mana tingkat kesalahan menurun tajam dari *epoch* pertama hingga mencapai titik terendahnya di sekitar *epoch* 300 dengan nilai 0,008583. Fenomena di mana nilai MSE validasi secara konsisten lebih rendah daripada MSE pelatihan menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik terhadap data baru. Selain itu, Tidak ditemukannya deviasi yang signifikan atau perpotongan ekstrim antara kurva *training* (garis merah) dan kurva *validation* (garis hijau) membuktikan bahwa model tidak mengalami *overfitting* [34]. Sebaliknya, nilai MSE validasi yang secara konsisten berada di bawah MSE pelatihan menunjukkan bahwa mekanisme *Transfer Learning* dan generalisasi yang diterapkan bekerja dengan sangat baik, di mana model mampu mempertahankan tingkat kesalahan yang rendah saat diuji pada data yang belum pernah dilihat sebelumnya (*target domain*). Kondisi ini membuktikan ketangguhan (*robustness*) model dalam memberikan prediksi yang akurat dan reliabel lintas kohort siswa. Oleh karena itu, model dinyatakan sangat layak untuk dilanjutkan ke tahap evaluasi akhir menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

### 3.2 Validasi dan Evaluasi

Validasi pada pengujian ke-9 menunjukkan performa yang lebih unggul dibandingkan dengan uji ke-10, sehingga parameter pada iterasi tersebut dipilih sebagai basis prediksi. Pengujian dilakukan secara komprehensif menggunakan skema backward-generalization, di mana model dilatih menggunakan data siswa Kelas XII sebagai *source domain* dan diuji pada data Kelas XI sebagai *target domain*. Hasilnya, model menunjukkan tingkat efektivitas yang sangat tinggi dalam melakukan klasifikasi multilabel untuk paket mata pelajaran pilihan. Penerapan learning analytics dalam konteks ini tidak hanya bertujuan untuk mencapai akurasi teknis, tetapi juga untuk mengoptimalkan lingkungan belajar dengan memberikan wawasan yang presisi dan dapat ditindaklanjuti bagi para pemangku kepentingan dalam implementasi Kurikulum Merdeka. Seluruh capaian metrik performa dari hasil evaluasi tersebut disajikan secara detail pada tabel 2 berikut:

Tabel 2. Validasi Model

No.	Metrik Evaluasi	Hasil	Keterangan
1.	<i>Accuracy</i>	91,52%	Layak
2.	<i>Precision</i>	99,71%	Sangat Layak
3.	<i>Recall</i>	91,72%	Layak
4.	<i>F1-Score</i>	95,55%	Layak

Model yang dikembangkan dalam penelitian ini menunjukkan hasil yang sangat memuaskan dengan capaian *Accuracy* sebesar 91,52%, yang mengonfirmasi bahwa sebagian besar rekomendasi yang dihasilkan oleh sistem adalah benar. Temuan kunci yang paling signifikan adalah nilai *Precision* yang mencapai 99,71%, di mana tingginya angka ini menjamin bahwa setiap rekomendasi paket mata pelajaran yang dihasilkan memiliki risiko kesalahan penempatan (*false positive*) yang sangat rendah. Tingkat presisi yang hampir sempurna tersebut membuktikan keandalan model dalam mengidentifikasi paket yang relevan, sejalan dengan aspirasi *learning analytics* untuk memberikan intervensi yang tepat guna meningkatkan pengalaman belajar siswa. Performa ini didukung pula oleh nilai *Recall* sebesar 91,72% dan *F1-Score* sebesar 95,55%.

Penerapan skema backward-generalization (Kelas XII ke Kelas XI) berfungsi sebagai uji out-of-distribution lintas kohort, membuktikan bahwa model mampu menangkap pola akademik fundamental yang tangguh (robust). Risiko bias pada data spesifik sekolah dipandang sebagai bentuk kontekstualisasi positif dalam kerangka Kurikulum Merdeka, di mana bobot jaringan merepresentasikan struktur pengetahuan riil di ekosistem sekolah setempat.

Perbandingan performa menunjukkan keunggulan *backpropagation* dibandingkan *random forest* dalam menangkap fitur laten non-linear pada hubungan bakat-minat siswa. Hasil uji coba mengonfirmasi bahwa *backpropagation* menghasilkan *precision* yang lebih tinggi, sementara *random forest* cenderung mengalami degradasi akurasi saat dihadapkan pada skema *backward-generalization* lintas jenjang. Hal ini membuktikan efektivitas jaringan saraf tiruan dalam melakukan adaptasi domain dibandingkan algoritma berbasis pohon keputusan pada data pendidikan yang kompleks [35]. Selain itu, personalisasi pendidikan berdasarkan pengalaman belajar juga terbukti lebih unggul dengan menggunakan *backpropagation* dibandingkan dengan metode rekomendasi lain seperti *collaborative filtering* yang seringkali menghadapi kendala *parsity* dan *cold start* [36].

Penelitian ini memiliki keterbatasan pada skala dataset yang bersifat lokal di satu satuan pendidikan, sehingga memerlukan proses retraining untuk implementasi di sekolah dengan struktur data historis yang berbeda. Selain itu, penggunaan aktivasi *sigmoid* pada arsitektur ini memiliki risiko *vanishing gradient* apabila lapisan tersembunyi ditambah secara signifikan. Oleh karena itu, penelitian selanjutnya disarankan untuk mengeksplorasi fungsi aktivasi seperti *ReLU* serta teknik optimasi yang lebih luas guna meningkatkan skalabilitas dan fleksibilitas model pada ekosistem pendidikan yang lebih *heterogen*.

## 4. KESIMPULAN

Algoritma *backpropagation* dengan arsitektur 13-13-4 dengan menerapkan *transfer learning* dan *normal initialization* telah menghasilkan kinerja yang sangat memuaskan. Dimana nilai *accuracy* dari model yang dikembangkan mencapai 91,52%. Dengan demikian arsitektur jaringan dengan algoritma *backpropagation* dapat digunakan sebagai rekomendasi bagi siswa Sekolah Menengah Atas (SMA) dalam menentukan paket pilihan mata pelajaran yang sesuai dengan kompetensi masing-masing siswa secara personal. Rekomendasi yang dihasilkan dapat membantu siswa dalam meyakini terhadap potensi yang dimiliki guna mengembangkan karir di masa depan. Rekomendasi yang dihasilkan bukan sebatas asumsi karena berdasarkan data bakat, minat dan

kemampuan siswa yang saling berkaitan. Selain itu, rekomendasi yang dihasilkan juga merupakan gambaran terhadap keunggulan dan kelemahan siswa pada mata pelajaran tertentu.

Skalabilitas dataset pada penelitian ini yang masih terfokus pada satu satuan pendidikan. Kondisi ini menimbulkan risiko bias dan *overfitting* terhadap lingkungan sekolah yang spesifik. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas cakupan dataset dari berbagai sekolah dengan karakteristik yang *heterogen* guna meningkatkan kemampuan generalisasi model. Selain itu, pengembangan model ke depan perlu diarahkan pada integrasi ke dalam platform berbasis web atau aplikasi mobile untuk meningkatkan aksesibilitas bagi guru Bimbingan Konseling (BK) dan siswa dalam mendapatkan wawasan secara real-time dan personal.

## DAFTAR PUSTAKA

- [1] A. Aryanto et al., Panduan Pemilihan Mata Pelajaran Pilihan di SMA/MA/Bentuk Lain yang Sederajat, Jakarta: Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi, 2022.
- [2] F. Zulfikar, "https://www.detik.com/," 26 11 2021. [Online]. Available: <https://www.detik.com/edu/detikpedia/d-5828770/87-persen-mahasiswa-ri-merasa-salah-jurusan-apa-sebabnya>. [Accessed 22 09 2025].
- [3] A. A. Butt et al., "Comparative analysis of the rule-based and machine learning approach for assessing student reflections," in *International Society of the Learning Series*, Hiroshima, 2022.
- [4] A. Hosna, E. Merry, J. Gyalmo, Z. Alom, Z. Aung and M. A. Azim, "Transfer Learning: a Friendly Introduction," *Journal of Big Data*, vol. 9, p. 102, 2022.
- [5] S. M. Bhatt, K. Verbert and W. V. D. Noortgate, "Teacher-Centric Educational Recommender Systems In K12 Practice: Usage and Evaluation," *Heliyon*, vol. 11, p. e42012, 2025.
- [6] C. F. Rodriguez-Hernandez, M. Musso, E. Kyndt and E. Cascallar, "Artificial Neural Networks In Academic Performance Prediction: Systematic Implementation and Predictor Evaluation," *Computers and Education: Artificial Intelligence*, vol. 2, p. 100018, 3 2021.
- [7] N. Endut, W. M. A. F. W. Hamzah, I. Ismail, M. K. Yusof, Y. A. Baker and H. Yusoff, "A Systematic Literature Review on Multi-Label Classification based on Machine Learning Algorithms," *TEM Journal*, vol. 11, pp. 658-666, 2022.
- [8] S. Algarni and F. T. Sheldon, "Personalized Course Recommendations Leveraging Machine and Transfer Learning Toward Improved Student Outcomes," *machine learning and knowledge extraction*, vol. 7, p. 138, 11 2025.
- [9] D.E. Rumelhart et al., "Learning Representations By Back-propagating Errors," *Nature*, vol. 323, pp. 533-536, 1986.
- [10] M. Sabzi-Nojadeh et al., "Modeling the Essential Oil and Trans-Anethole Yield of Fennel (*Foeniculum vulgare* Mill. var. *vulgare*) by Application Artificial Neural Network and Multiple Linear Regression Methods," *agriculture*, p. 17, 26 11 2021.
- [11] A. I. Rodriguez P. and X. D. Buitrago R., "How to Choose an Activation Function for Deep Learning," *Tekhne*, vol. 19, pp. 23-32, 5 2022.
- [12] M. F. V. Ruslau, R. A. Pratama, M. Betaubun and D. R. Suryani, "Multiclass Classification Using Backpropagation," *IJCST-ICST*, vol. 012037, p. 1454, 2024.
- [13] Y. Cui et al., "Investigation On The Ignition Delay Prediction Model of Multi-Component Surrogates Based On Back Propagation (BP) Neural Network," *Combustion and Flame*, p. 16, 19 11 2021.
- [14] S. Nasir and A.S. Berrouk, "Numerical and Intelligent Neuro-Computational Modelling With Fourier's Energy and Fick's Mass Flux Theory of 3D Fluid Flow Through a Stretchable Surface," *Engineering Applications of Computational Fluid Mechanics*, vol. 17, p. 21, 2023.
- [15] G. M. M. Alshmrani et al., "A Deep Learning Architecture For Multi-Class Lung Diseases Classification Using Chest X-Ray (CXR) Images," *Alexandria Engineering Journal*, vol. 64, pp. 923-935, 2022.
- [16] I. Kamarudin et al., "Bab 5 Teknik Pengumpulan Data," in *Metodologi Penelitian Kuantitatif*, Padang, PT. Global Eksekutif Teknologi, 2023, p. 68.
- [17] M. Prasad and Srikanth T, "Clustering Accuracy Improvement Using Modified Min-Max Normalization Technique," *Preprint.org*, p. 4, 2024.
- [18] D. Gostautaitė and L. Sakalauskas, "Multi-Label Classification and Explanation Methods for Students

- Learning Style Prediction and Interpretation," *Applied Science*, vol. 12, p. 5396, 5 2022.
- [19] N. L. Rane, S. P. Choudhary and J. Rane, "Ensemble Deep Learning and Machine Learning: Application, Opportunities, Challenges, and Future Directions," *Studies in Medical and Health Sciences*, vol. 5, no. 2, pp. 18-41, 2024.
- [20] M. Iman, H. R. Arabnia and K. Rasheed, "A Review of Deep Transfer Learning and Recent Advancements," *MDPI*, vol. 11, p. 40, 3 2023.
- [21] A. Geron, *Hands-on Machine Learning with Scikit-Learn, Keras & TensorFlow*, Sebastopol: O'Reilly Media, Inc, 2019.
- [22] K. Wong, R. Dornberger, and T. Hanne, "An Analysis of Weight Initialization Methods In Connection With Different Activation Functions For Feedforward Neural Networks," *Evolutionary Intelligence*, p. 9, 2022.
- [23] C. Desai, "Impact of Weight Initialization Techniques on Neural Network Efficiency and Performance: A Case Study with MNIST Dataset," *www.ijecs.in*, vol. 13, p. 6, 2024.
- [24] M. M. Hammad, *Artificial Neural Network and Deep Learning: Fundamentals and Theory*, Damanhour, 2024.
- [25] O. A. M. Lopez, A. M. Lopez and J. Crossa, *Multivariate Statistical Machine Learning Methods for Genomic Prediction*, Mexico: Springer, 2022.
- [26] S. T. J. and K. K. E. , "Impact of Weight Initialization on the Performance of Neural Networks," *Applied Sciences*, vol. 12, p. 2456, 2022.
- [27] H. Lee, Y. Kim, S. Y. Yang and H. Choi, "Improved Weight Initialization for Deep and Narrow Feedforward Neural Network," *Neural Network*, p. 176, 2024.
- [28] Z. Sabir and M. Umar, "Levenberg-Marquardt Backpropagation Neural Network Procedures for The Consumption of Hard Water-Based Kidney Function," *International Journal of Mathematics and Computer in Engineering*, vol. 1, pp. 127-138, 2023.
- [29] D. Vithanage et al., "Evaluating Approaches of Training a Generative Large Language Model for Multi-Label Classification of Unstructured Electronic Health Records," *MedRxiv*, p. 25, 2024.
- [30] P. S. Rana, Kalpana, Chahat, S. K. Modi, A. L. Yadav and S. Singla, "Comparative Analysis of Tree-Based Models and Deep Learning Architectures for Tabular Data:," in *ICACCTech*, 2023.
- [31] T. Sutojo, E. Mulyanto and V. Suhartono, *Kecerdasan Buatan*, Yogyakarta: Penerbit Andi, 2011.
- [32] I. Goodfellow, Y. Bengio and A. Courville, *Deep Learning*, MIT, 2017.
- [33] P. Mirza, A. Vates, F. Ferizbegovic, H. Bajric and M. Pasic, "Machine Learning Prediction and Analysis of Students' Academic Performance," *Periodicals of Engineering and Natural Sciences*, vol. 11, pp. 27-46, 10 2023.
- [34] P. A. J. , P. R. H. Y. and F. M. A., "Optimization of Artificial Neural Network using Sigmoid Activation Function for Prediction," *Journal of Physics: Conference Series*, vol. 1899, p. 012112, 2021.
- [35] E. Chris, A. Johnson and G. Phonix, "Deep Learning vs. Traditional Machine Learning: Key Differences," 11 2024.
- [36] C. Li, I. Ishak, H. Ibrahim, M. Zolkepli, F. Sidi and C. Li, "Deep Learning-Based Recommendation System: Systematic Review and Classification," *IEEE Access*, vol. 11, pp. 113790-113835, 10 2023.