

Model Prediksi Prestasi Mahasiswa ITAF Kupang Menggunakan Backpropagation Berbasis Data Perilaku Belajar

Mohamad Iqbal Ulumando^{1*}

Program Studi Informatika, Institut Teknologi Alberth Foenay Kupang
Jl. Tidar RT. 044, RW. 014, Kel. Oesapa, Kec. Kelapa Lima, Kota Kupang - NTT
E-mail: iqbal77ulumando@gmail.com

Submitted Date : 03 Juni 2025 Accepted Date : 04 Juli 2025

Abstrak - Prestasi akademik mahasiswa dipengaruhi oleh berbagai faktor, salah satunya adalah perilaku belajar yang mencakup kehadiran, penyelesaian tugas, serta partisipasi dalam ujian. Penelitian ini bertujuan membangun model prediksi prestasi akademik mahasiswa berdasarkan perilaku belajar dengan menerapkan algoritma Backpropagation. Data diperoleh dari 85 mahasiswa Program Studi Informatika ITAF Kupang angkatan 2024, yang mencakup lima variabel: kehadiran, nilai tugas, keterlambatan pengumpulan tugas, nilai UTS, dan nilai UAS. Model dikembangkan menggunakan arsitektur multi-layer perceptron dengan data yang telah dinormalisasi. Hasil evaluasi menunjukkan bahwa model mampu mengklasifikasikan kategori prestasi akademik dengan akurasi sebesar 91,17% dan nilai Mean Squared Error (MSE) sebesar 0,2359. Performa model dibandingkan dengan tiga metode baseline, yaitu Naïve Bayes (77,5%), Decision Tree C4.5 (91,67%), dan K-Means Clustering menunjukkan bahwa Backpropagation memiliki performa prediktif yang kompetitif, terutama dalam menangani data non-linear antar variabel. Kebaruan penelitian ini terletak pada penggunaan dataset mahasiswa ITAF Kupang yang belum pernah diteliti sebelumnya serta konfigurasi pelatihan model yang disesuaikan. Penelitian ini diharapkan dapat mendukung pengembangan sistem prediksi akademik berbasis data di perguruan tinggi.

Kata kunci : Prediksi; Prestasi; Perilaku Belajar; Backpropagation; Mahasiswa ITAF Kupang.

Abstract - Student academic achievement is influenced by various factors, one of which is learning behavior which includes attendance, assignment completion, and participation in exams. This study aims to build a prediction model for student academic achievement based on learning behavior by applying the Backpropagation algorithm. Data were obtained from 85 students of the ITAF Kupang Informatics Study Program, class of 2024, which included five variables: attendance, assignment grades, late assignment submission, mid-term exam grades, and final exam grades. The model was developed using a multi-layer perceptron architecture with normalized data. The evaluation results showed that the model was able to classify academic achievement categories with an accuracy of 91.17% and a Mean Squared Error (MSE) value of 0.2359. Model performance compared to three baseline methods, namely Naïve Bayes (77.5%), Decision Tree C4.5 (91.67%), and K-Means Clustering showed that Backpropagation has competitive predictive performance, especially in handling non-linear data between variables. The novelty of this research lies in the use of ITAF Kupang student datasets that have never been studied before and the customized model training configuration. This research is expected to support the development of data-based academic prediction systems in higher education.

Keywords: Prediction; Achievement; Learning Behavior; Backpropagation; ITAF Kupang Students.

1. Pendahuluan

Prestasi akademik mahasiswa merupakan salah satu parameter penting yang digunakan untuk menilai keberhasilan proses pendidikan di perguruan tinggi [1]. Faktor-faktor seperti kemampuan intelektual, metode pembelajaran, serta perilaku belajar seperti kehadiran dan penyelesaian tugas sangat memengaruhi pencapaian akademik [2]. Salah satu pendekatan yang dapat digunakan untuk mencapai tujuan tersebut adalah dengan memanfaatkan teknologi jaringan syaraf tiruan (artificial neural networks), khususnya metode Backpropagation Neural Network [3].

Metode Backpropagation Neural Network telah terbukti efektif dalam berbagai aplikasi, termasuk dalam memprediksi prestasi akademik mahasiswa [4]. Penelitian oleh Mini Agarwal dan Dr. Bharat Bhushan Agarwal [5] menunjukkan bahwa Backpropagation dapat mencapai akurasi hingga 98% dalam memprediksi prestasi akademik mahasiswa dengan menggunakan data historis yang mencakup berbagai faktor seperti nilai ujian, kehadiran, dan tugas yang diselesaikan. Demikian pula, penelitian oleh Muftikhah dan Hindayati Mustafidah [6] menyoroti kombinasi jaringan syaraf tiruan backpropagation dengan logika fuzzy untuk memprediksi klasifikasi prestasi belajar mahasiswa berdasarkan faktor-faktor internal dan eksternal.

Selain itu, penelitian oleh Noni Fauzia Rahmadani, Agung Nugroho, dan Lailan Sofinah Haharap [7] juga mengindikasikan bahwa Backpropagation merupakan alat yang sangat efektif dalam memprediksi nilai mahasiswa berdasarkan riwayat akademik menggunakan Jaringan Syaraf Tiruan dengan metode Backpropagation. Meskipun data yang digunakan terbatas, model ini mampu memberikan prediksi yang akurat dengan nilai Mean Square Error (MSE) sebesar 0.01363 dalam 68 epoch. Selain itu, penelitian oleh I Putu Bagus Arya Pradnyana dan I Gusti Agung Made Sunaya [8], menyoroti pentingnya keberhasilan mahasiswa sebagai indikator kualitas lembaga pendidikan tinggi, yang dinilai dari berbagai aspek seperti prestasi akademik, kehadiran, dan keterampilan. Fokus utamanya adalah memprediksi keberhasilan mahasiswa berdasarkan data kehadiran menggunakan metode kecerdasan buatan, khususnya algoritma Backpropagation. Hasil penelitian menunjukkan bahwa metode ini mampu melakukan peramalan dengan tingkat kesalahan (MSE) yang rendah, khususnya pada semester 3 yang mencatat MSE terkecil sebesar 0,0388 sekaligus menunjukkan IPK tertinggi.

Beberapa penelitian sebelumnya telah mengusulkan pendekatan berbeda dalam memprediksi prestasi siswa atau mahasiswa. Rofilde Hasudungan dan Wawan Joko Pranoto [9] menerapkan algoritma Naïve Bayes dengan akurasi 77,5% untuk prediksi prestasi mahasiswa berdasarkan data latar belakang keluarga untuk mengukur prestasi mahasiswa yang diukur dari nilai IPK, memperlihatkan bahwa pendekatan klasifikasi sederhana pun mampu memberikan hasil yang cukup kompeten. Selanjutnya, Prestian Ramadhan, Yuhandri dan Jhon Veri [10] menggunakan algoritma Decision Tree C4.5 untuk klasifikasi siswa berprestasi di SMPN 1 Kerinci dengan akurasi mencapai 91,67%, menekankan pengaruh besar faktor non-akademik seperti nilai akhlak dan disiplin. Sementara itu, Shafia Natalia Br Sembiring, Hendryan Winata, Sri Kusnari [11] menerapkan algoritma K-Means untuk mengelompokkan prestasi siswa dan menunjukkan keunggulan sistem berbasis clustering dalam mendeteksi kategori prestasi siswa dengan akurasi hasil yang signifikan.

Sebelumnya ada dua penelitian yang dilakukan oleh penulis menggunakan metode Backpropagation dalam melakukan prediksi yaitu Prediksi hasil produksi tanaman kopi [12], dan prediksi hasil produksi jambu mete [13]. Dalam penelitian tersebut, Backpropagation digunakan untuk memprediksi hasil produksi kopi dan jambu mete untuk beberapa tahun yang akan datang dengan menggunakan variabel pada tahun sebelumnya dan menghasilkan model prediksi dengan akurasi yang cukup tinggi. Dari kedua penelitian ini memperkuat bukti bahwa Backpropagation dapat diaplikasikan untuk memprediksi hasil produksi berdasarkan data yang sudah ada, termasuk dalam konteks ini adalah prediksi model prestasi akademik mahasiswa.


Melalui penelitian ini, kami bertujuan untuk mengembangkan sebuah model prediksi prestasi akademik mahasiswa di ITAF Kupang dengan menggunakan Backpropagation Neural Network yang berbasis pada data perilaku belajar mahasiswa yang meliputi persentase kehadiran mahasiswa, nilai tugas, keterlambatan pengumpulan tugas, nilai UTS dan nilai UAS. Meskipun kampus ITAF Kupang belum memiliki Learning Management System (LMS) yang terintegrasi dengan baik, data akademik yang tersedia sudah cukup untuk membangun model prediksi yang dapat digunakan untuk menganalisis dan meningkatkan prestasi mahasiswa secara lebih terstruktur.

2. Tinjauan Pustaka

2.1. Jaringan Syaraf Tiruan (JST)

Jaringan Saraf Tiruan (JST) merupakan salah satu bentuk pemodelan komputasional yang meniru mekanisme kerja otak manusia dalam memproses dan mempelajari informasi. Disebut buatan karena jaringan ini dibangun menggunakan algoritma yang dijalankan oleh komputer untuk menyelesaikan berbagai perhitungan dalam proses pembelajaran [14]. Secara umum jaringan syaraf tiruan mempunyai tiga layer yaitu: layer input, layer tersembunyi (Hidden Layer), dan layer output.

Jaringan Syaraf Tiruan




Gambar 1. Jaringan Syaraf Tiruan

Tiga karakteristik pada jaringan syaraf tiruan (JST) adalah : Jaringan Arsitektur yang berfungsi mengelola neuron pada lapisan dengan bobot yang saling berhubungan. Kemudian jaringan dengan algoritma yang : berfungsi mencari nilai bobot. Serta Fungsi Aktivasi yang berfungsi sebagai penentuan nilai output dari total nilai inputan pada neuron [15].


2.2. Algoritma Backpropagation

Backpropagation merupakan suatu algoritma pelatihan jaringan saraf tiruan (Artificial Neural Network) yang digunakan untuk meminimalkan kesalahan keluaran (error output) melalui proses pembelajaran terarah (*supervised learning*) [16]. Algoritma ini bekerja dengan cara melakukan propagasi maju (*forward propagation*) untuk menghasilkan keluaran, menghitung selisih atau error antara keluaran aktual dan target, kemudian melakukan propagasi balik (*backward propagation*) guna memperbarui bobot pada setiap neuron berdasarkan metode *gradient descent* [17]. Proses Fordward dan Backward Propagation ditampilkan pada gambar 2 berikut ini.



Gambar 2. Proses Fordward dan Backward Propagation

Backpropagation sangat efektif dalam pelatihan jaringan dengan lebih dari satu lapisan tersembunyi (*multi-layer perceptron*) dan telah menjadi landasan bagi banyak aplikasi kecerdasan buatan, termasuk pengenalan pola, klasifikasi, dan prediksi [18]. Keunggulannya terletak pada kemampuan untuk menyesuaikan parameter jaringan secara otomatis guna meningkatkan akurasi output seiring berjalannya proses pelatihan [19]. Multi-layer perceptron ditampilkan pada gambar 3 berikut ini.



Gambar 3. Multi-layer perceptron

Pelatihan Backpropagation pada jaringan saraf tiruan (neural network) digunakan dalam penyelesaian berbagai permasalahan seperti identifikasi, prediksi, dan pengenalan pola. Algoritma ini bekerja dengan memperbaiki bobot berdasarkan nilai error output, sehingga dapat menghasilkan output yang lebih akurat pada proses forward propagation. Aktivasi neuron dilakukan melalui fungsi yang dapat didiferensiasikan, seperti fungsi sigmoid, dengan menggunakan persamaan sebagai berikut [13].

$$y = F(X) = \frac{1}{1+e^{-\alpha X}} \quad (1)$$

$$f'(X) = \sigma f(X)[1 - f(X)] \quad (2)$$

Atau seperti tangent sigmoid :

$$y = F(X) = \frac{e^X - e^{-X}}{e^X + e^{-X}} \quad (3)$$

$$f'(X) = [1 + f(X)][1 - f(X)] \quad (4)$$

Urutan latihan Backpropagation sebagai berikut.

Urutan 0: Bobot Di inisialisasi

Urutan 1: Jika kondisi berhenti, nilainya salah, maka kerjakan urutan 2-9;

Urutan 2: Urutan 3-8 yaitu latihan data.

Feedforward (Umpan Maju)

Urutan 3: Setiap unit input ($X_i, i = 1, \dots, n$) menerima sinyal input X_i dan menyebarkan sinyal tersebut ke seluruh unit tersembunyi.

Urutan 4: Pada unit tersembunyi ($Z_j, j = 1, \dots, p$) menunjukkan sinyal-sinyal input yang sudah berbobot (termasuk biasnya)

$$Z_{in_j} = v_{0j} + \sum_{i=1}^n X_i V_{ij} \quad (5)$$

Gunakan fungsi aktivasi untuk menghitung sinyal output dari unit tersembunyi :

$$Z_j = f(Z_{in_j}) \quad (6)$$

Kemudian sinyal output dikirim ke seluruh unit (unit output)

Urutan 5: Tiap-tiap output ($Y_k, k = 1, \dots, m$) menjumlahkan bobot sinyal input :

$$y_{in_k} = w_{0k} + \sum_{i=1}^n Z_i w_{jk} \quad (7)$$

Fungsi aktivasi digunakan untuk menghitung sinyal output dari unit output bersangkun.

$$y_k = f(y_{in_k}) \quad (8)$$

Sinyal output kemudian dikirim pada unit output.

Backpropagation of Error (Umpan Mundur/ Propagasi Error)

Urutan 6: Setiap unit output ($Y_k, k = 1, \dots, m$) menerima suatu pola target yang sesuai dengan pola input pelatihan, untuk menghitung kesalahan (error) antara target dengan output yang dihasilkan jaringan

$$\delta_k = (t_k - y_k) f'(y_{in_k}) \quad (9)$$

Factor δ_k digunakan untuk menghitung koreksi error (ΔW_{jk}) yang nantinya akan dipakai untuk memperbaiki

$$W_{jk}, \text{ dimana } \Delta W_{jk} = \alpha \delta_k Z_j$$

Selain itu juga dihitung koreksi bias ΔW_{0k} yang nantinya akan dipakai untuk memperbaiki W_{0k} , dimana

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

Faktor δ_k kemudian dikirim pada lapisan yang berada pada urutan 7.

Urutan 7: Setiap unit tersembunyi ($Z_j, j = 1, \dots, p$) menerima input delta (dari langkah ke-6) yang sudah berbobot

$$\delta_{in_j} = w_{0k} + \sum_{k=1}^m \delta_k w_{jk} \quad (10)$$

Kemudian hasilnya dikalikan dengan turunan dari fungsi aktivasi yang digunakan jaringan untuk menghitung informasi kesalahan error δ_j , dimana :

$$\delta_j = \delta_{in_j} f'(Z_{in_j}) \quad (11)$$

Kemudian hitunglah koreksi bobot (untuk memperbaiki V_{ij})

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (12)$$

Setelah itu hitung koreksi bias (digunakan untuk memperbaiki V_{0j})

$$\Delta v_{0j} = \alpha \delta_j \quad (13)$$

Adjustment (Update Bobot dan Bias)

Urutan 8: Setiap unit output ($Y_k, k = 1, \dots, m$) memperbaiki bobot dan bias dari setiap unit

tersembunyi ($j = 0, \dots, p$)

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{jk} \quad (14)$$

Demikian pula untuk setiap unit tersembunyi ($Z_j, j = 1, \dots, p$) akan memperbaharui bobot dan bias dari

setiap unit input ($i = 0, \dots, n$)

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (15)$$


Urutan 9: Test kondisi berhenti apabila error ditemukan

Jika kondisi STOP telah terpenuhi, maka pelatihan jaringan dapat dihentikan. Untuk memeriksa kondisi STOP, biasanya digunakan kriteria MSE (Mean Square Error)

Secara keseluruhan, algoritma backpropagation telah terbukti menjadi metode yang sangat efektif dalam berbagai aplikasi, mulai dari analisis sentimen, klasifikasi medis, hingga prediksi tingkat kelulusan. Keunggulan dalam menyesuaikan bobot jaringan dan meningkatkan akurasi seiring berjalannya waktu membuatnya menjadi alat yang sangat relevan dalam pengembangan kecerdasan buatan. Dengan terus berkembangnya penelitian dan penerapannya, backpropagation menunjukkan potensi besar untuk digunakan dalam berbagai domain, membuka peluang untuk inovasi lebih lanjut dalam pemrosesan data dan pengambilan keputusan berbasis teknologi.

3. Metode Penelitian

Pengumpulan data dilakukan sebagai awal dalam penelitian ini, data berupa persentase kehadiran mahasiswa, nilai tugas, keterlambatan pengumpulan tugas, nilai UTS dan nilai UAS diambil berdasarkan Rekap akademik dan dokumentasi dari pengajar atau dosen yang dijadikan sebagai variabel dalam penelitian ini. Adapun alur penelitian ditampilkan pada gambar 4 berikut ini.



Gambar 4. Alur Penelitian

Setelah data akademik mahasiswa ITAF Kupang dikumpulkan, dilakukan Pra-pemrosesan Data (Seleksi dan Normalisasi) dimana, Data mentah dibersihkan dari data yang tidak lengkap atau outlier [12]. Selanjutnya dilakukan normalisasi dengan menggunakan persamaan sebagai berikut :

$$X' = (0,8(X-b)/(a-b)) + 0,1 \quad (16)$$

Jaringan syaraf tiruan dibangun dengan konfigurasi I :

- ✓ **Input layer** : 4–5 neuron (sesuai jumlah variabel input)
- ✓ **Hidden layer** : 1 atau lebih layer dengan jumlah neuron hasil uji coba (eksperimen)
- ✓ **Output layer** : 1 neuron untuk klasifikasi prestasi akademik (Rendah, Sedang, Tinggi)

Model dilatih menggunakan data latih (80%) dengan parameter : Learning rate: 0.1 – 0.5, Epoch maksimum: 1000, dan Target error : 0.001. Pelatihan dilakukan menggunakan algoritma *Backpropagation* yang memperbarui bobot berdasarkan error yang dihitung.

Model yang telah dilatih diuji menggunakan data uji (20%) untuk mengukur kemampuannya dalam memprediksi kategori prestasi mahasiswa yang belum dikenali oleh sistem. Performa model dievaluasi dengan :

- ✓ **Akurasi** : Persentase prediksi yang benar
- ✓ **Confusion matrix** : Untuk melihat detail klasifikasi
- ✓ **F1-Score** : Kombinasi precision dan recall untuk menilai kualitas prediksi

Hasil evaluasi dianalisis untuk mengetahui tingkat keberhasilan model dan hubungan antara variabel perilaku belajar dengan prestasi akademik mahasiswa. Hasil akhirnya adalah sebuah *model prediksi*, tetapi model tersebut digunakan untuk mengklasifikasikan atau memetakan mahasiswa ke dalam kategori prestasi akademik (Tinggi, Sedang, Rendah) berdasarkan perilaku belajar mereka. Proses penelitian diakhiri dengan penarikan kesimpulan dari hasil analisis, serta dokumentasi hasil dan rekomendasi untuk pengembangan lebih lanjut.

4. Hasil dan Pembahasan

4.1. Data yang Dikumpulkan :

Sampel yang digunakan adalah data Mahasiswa Program Studi Informatika Institut Teknologi Alberth Foenay (ITAF) Kupang angkatan 2024. Total mahasiswa yang digunakan sebagai sampel penelitian ini adalah : 85 Mahasiswa. Rata-rata persentase kehadiran mahasiswa dalam perkuliahan adalah : 80% dan

nilai rata-rata tugas yang diberikan oleh dosen adalah : 75. Dari 85 mahasiswa, sebanyak 28 mahasiswa terlambat mengumpulkan tugas. Persentase keterlambatannya adalah : $\frac{28}{85} \times 100 = 32,94\%$ Mahasiswa.

Untuk Nilai Ujian Tengah Semester (UTS) : 70% mahasiswa mendapatkan nilai antara 70 hingga 80. 20% mahasiswa mendapatkan nilai antara 81 hingga 100. 9% mahasiswa mendapatkan nilai antara 50 hingga 69. 1% mahasiswa mendapatkan nilai antara 0 hingga 49. Sedangkan Nilai Ujian Akhir Semester (UAS) : 62% mahasiswa mendapatkan nilai antara 70 hingga 80. 27% mahasiswa mendapatkan nilai antara 81 hingga 100. 6% mahasiswa mendapatkan nilai antara 50 hingga 69. 5% mahasiswa mendapatkan nilai antara 0 hingga 49.

4.2. Pengolahan Data :

Untuk keperluan penelitian, persentase kehadiran mahasiswa dan keterlambatan pengumpulan tugas dapat dihitung secara rata-rata atau dipetakan ke dalam data numerik. Kategori prestasi akademik bisa ditentukan berdasarkan gabungan nilai UTS, UAS, dan nilai tugas untuk memudahkan klasifikasi.

1. Normalisasi Data

Agar semua data berada dalam rentang yang sama (0–1), lakukan normalisasi untuk variabel persentase kehadiran, nilai tugas, keterlambatan pengumpulan tugas, nilai UTS dan UAS.

2. Klasifikasi Prestasi Akademik

Tentukan kategori Rendah, Sedang, atau Tinggi berdasarkan nilai gabungan dari persentase kehadiran mahasiswa, nilai tugas, keterlambatan pengumpulan tugas, nilai UTS dan nilai UAS.

4.3. Normalisasi Data

Normalisasi digunakan untuk memastikan bahwa semua data variabel berada dalam skala yang sama (0–1) sehingga model lebih efisien dalam pelatihan. Berikut adalah perhitungan normalisasinya : $X' = (0,8(X-b)/(a-b)) + 0,1$

Keterangan :

X = Nilai Asli

a = Nilai Maksimum

b = Nilai Minimum

X' = Nilai Setelah Normalisasi

Range Hasil = 0.1 – 0.9

Tabel 1. Asumsi Nilai Minimum dan Maksimum Tiap Variabel

Variabel	Min (b)	Max (a)	Nilai Sampel
Kehadiran (%)	0	100	80
Nilai Tugas	0	100	75
Keterlambatan (%)	0	100	32,94
Nilai UTS	0	100	75 (diasumsikan dari kisaran dominan 70–80)
Nilai UAS	0	100	78 (diasumsikan dari kisaran dominan 70–80)

Perhitungan Tiap Varibel Adalah sebagai berikut.

1. Kehadiran (80%)

$$X' = 0.8 \left(\frac{80-0}{100-0} \right) + 0.1$$

$$0.8 \times 0.8 = 0.64$$

$$0.64 + 0.1 = 0.74$$

2. Nilai Tugas 75

$$X' = 0.8 \left(\frac{75-0}{100-0} \right) + 0.1$$

$$0.8 + 0.75 = 0.6$$

$$0.6 + 0.1 = 0.70$$

3. Keterlambatan (32.94%)

$$X' = 0.8 \left(\frac{32.94-0}{100-0} \right) + 0.1$$

$$0.8 + 0.3294 = 0.2635$$

$$0.2635 + 0.1 = 0.3635$$

4. Nilai UTS (75)

$$X' = 0.8 \left(\frac{75-0}{100-0} \right) + 0.1$$

$$0.8 + 0.75 = 0.6$$

$$0.6 + 0.1 = 0.70$$

5. Nilai UAS (78)

$$X' = 0.8 \left(\frac{78-0}{100-0} \right) + 0.1$$

$$0.8 + 0.75 = 0.624$$

$$0.624 + 0.1 = 0.724$$

Dari perhitungan kehadiran (%), nilai tugas, keterlambatan (%), nilai UTS, dan nilai UAS diatas, maka dapat diketahui nilai normalisasinya. Untuk lebih jelas ditampilkan pada tabel 2 berikut ini.

Tabel 2. Hasil Normalisasi Data Sampel

Variabel	Nilai Asli	Normalisasi
Kehadiran (%)	80	0.74
Nilai Tugas	75	0.70
Keterlambatan (%)	32.94	0.3635
Nilai UTS	75	0.70
Nilai UAS	78	0.724

4.4. Membangun dan Melatih Model Backpropagation

Setelah seluruh variabel perilaku belajar mahasiswa dinormalisasi ke dalam rentang [0.1, 0.9] menggunakan pendekatan *Min-Max Scaling*, tahap selanjutnya adalah membangun dan melatih model prediksi prestasi akademik dengan algoritma Backpropagation Neural Network. Model ini dirancang untuk menerima lima input yang telah dinormalisasi, yaitu kehadiran, nilai tugas, keterlambatan pengumpulan tugas, nilai UTS, dan nilai UAS.


Jaringan neural dibangun dengan arsitektur multi-layer perceptron, terdiri atas satu lapisan input (5 neuron), satu lapisan tersembunyi (10 neuron), dan satu lapisan output (1 neuron dengan klasifikasi multi-kelas). Model menggunakan fungsi aktivasi sigmoid (logistic), serta parameter pelatihan berupa laju pembelajaran (learning rate) sebesar 0.3 dan batas maksimum iterasi (epoch) sebanyak 1000. Proses ini diawali dengan forward propagation, di mana input yang telah dinormalisasi dikalikan dengan bobot dan dijumlahkan, kemudian dilewatkan ke fungsi aktivasi sigmoid :

$$f(x) = \frac{1}{1 + e^{-x}}$$

Output yang dihasilkan dibandingkan dengan label target sebenarnya (Tinggi, Sedang, Rendah) untuk menghitung nilai kesalahan (error). Fungsi kesalahan yang digunakan adalah Mean Squared Error (MSE) :

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

Nilai kesalahan tersebut digunakan dalam tahap backward propagation, yang menghitung gradien dari fungsi kesalahan terhadap bobot-bobot jaringan untuk melakukan koreksi. Proses ini berlangsung hingga error menurun di bawah ambang batas atau jumlah epoch maksimum tercapai. Model kemudian dilatih dengan data sebanyak 85 mahasiswa, menggunakan skema split data sebesar 80% untuk pelatihan dan 20% untuk pengujian. Setelah pelatihan selesai, model menunjukkan hasil performa yang ditampilkan pada gambar 5 sebagai berikut.



Gambar 5. Pelatihan Model Backpropagation

Grafik akurasi menunjukkan bahwa model mencapai akurasi pelatihan (training accuracy) di akhir epoch sebesar 0.9558 (95.58%) dan akurasi validasi (uji/test accuracy) sebesar 0.9117 (91.17%). Selisih akurasi yang kecil menandakan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami overfitting. Tren grafik yang stabil juga menunjukkan bahwa proses pelatihan berlangsung efektif dan konvergen. Dengan hasil ini, model dinilai layak digunakan untuk memprediksi prestasi mahasiswa berdasarkan perilaku belajarnya. Untuk melihat detail implementasi kode program model ini, source code lengkap dapat diakses melalui repositori GitHub berikut:

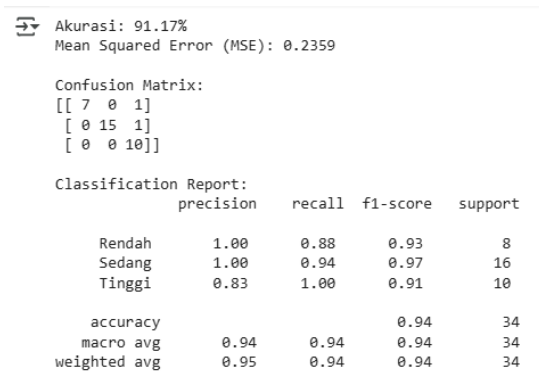
<https://github.com/iqbal77dotcom/Model-Prediksi-Prestasi-Mahasiswa-ITAF-Kupang-Menggunakan-Backpropagation>

4.5. Evaluasi Model

Evaluasi model dilakukan secara otomatis menggunakan Python untuk seluruh data uji, dengan mengukur akurasi, confusion matrix, precision, recall, F1-score, serta Mean Squared Error (MSE). Evaluasi ini bertujuan untuk mengetahui sejauh mana model dapat mengklasifikasikan data dengan benar pada data uji yang tidak dikenali sebelumnya. Implementasi pengujian evaluasi model dilakukan menggunakan bahasa Python dengan bantuan library *scikit-learn* dan *NumPy*. Source code lengkap pengujian evaluasi ini dapat diakses melalui repositori GitHub berikut:

<https://github.com/iqbal77dotcom/Model-Prediksi-Prestasi-Mahasiswa-ITAF-Kupang-Menggunakan-Backpropagation>

Hasil pengujian evaluasi model ditampilkan pada Gambar 6 sebagai berikut.



Gambar 6. Hasil Pengujian Evaluasi Model

Berdasarkan hasil evaluasi, model Backpropagation menunjukkan performa klasifikasi yang baik terhadap data uji. Model berhasil mencapai akurasi sebesar 91,17%, yang berarti 31 dari 34 data uji berhasil diprediksi dengan benar. Nilai Mean Squared Error (MSE) yang diperoleh sebesar 0,2359, mengindikasikan tingkat kesalahan prediksi yang rendah.

Confusion matrix menunjukkan bahwa dari 34 data uji, sebagian besar berhasil diklasifikasikan secara tepat ke dalam kategori *Rendah*, *Sedang*, dan *Tinggi*, dengan kesalahan minimal pada tiga data. Nilai precision, recall, dan f1-score pada masing-masing kelas juga tergolong tinggi, dengan rata-rata nilai f1-score sebesar 0,94. Hal ini menunjukkan bahwa model mampu mengklasifikasikan kategori prestasi secara akurat.

dan merata pada semua kelas. Secara keseluruhan, hasil ini membuktikan bahwa model memiliki kemampuan generalisasi yang baik dan layak diterapkan untuk prediksi prestasi mahasiswa berdasarkan perilaku belajar.

4.6. Prediksi dengan Model

Setelah melalui tahap pelatihan dan evaluasi, model Backpropagation yang telah dibangun digunakan untuk melakukan proses prediksi terhadap data uji. Tujuan dari proses ini adalah untuk mengklasifikasikan mahasiswa ke dalam kategori prestasi akademik, yaitu Rendah, Sedang, dan Tinggi, berdasarkan perilaku belajarnya. Implementasi proses prediksi dilakukan menggunakan bahasa pemrograman Python, dengan memanfaatkan model yang telah dilatih sebelumnya. Seluruh kode program terkait proses prediksi ini telah didokumentasikan dan dapat diakses secara terbuka melalui repositori GitHub berikut : <https://github.com/iqbal77dotcom/Model-Prediksi-Prestasi-Mahasiswa-ITAF-Kupang-Menggunakan-Backpropagation>

Berikut adalah hasil dari pengujian prediksi dengan model Backpropagation yang ditampilkan pada gambar 7.

	Kehadiran (%)	Nilai Tugas	Keterlambatan (%)	Nilai UTS	Nilai UAS	\
1	82,48	71,49	20	68	89	
2	79,31	81,41	20	77	59	
3	83,24	77,30	40	75	92	
4	87,62	71,29	20	86	93	
5	78,83	78,59	40	75	78	
6	78,83	75,68	30	72	62	
7	87,90	81,78	30	58	61	
8	83,84	70,09	30	61	80	
9	77,65	72,71	30	50	95	
10	82,71	72,26	20	50	51	
Prediksi Prestasi						
1						Sedang
2						Sedang
3						Sedang
4						Sedang
5						Sedang
6						Sedang
7						Sedang
8						Sedang
9						Sedang
10						Sedang

Gambar 7. Hasil Dari Pengujian Prediksi Dengan Model Backpropagation

Untuk lebih lengkap hasil prediksi prestasi mahasiswa ITAF Kupang menggunakan model backpropagation dapat dilihat pada tabel 3 berikut ini.

Tabel 3. Hasil Prediksi Prestasi Mahasiswa ITAF Kupang

No	Kehadiran (%)	Nilai Tugas	Keterlambatan (%)	Nilai UTS	Nilai UAS	Prediksi Prestasi
1	82,48	71,49	20	68	89	Sedang
2	79,31	81,41	20	77	59	Sedang
3	83,24	77,3	40	75	92	Sedang
4	87,62	71,29	20	86	93	Sedang
5	78,83	78,59	40	75	78	Sedang
6	78,83	75,68	30	72	62	Sedang
7	87,90	81,78	30	58	61	Sedang
8	83,84	70,09	30	61	80	Sedang
9	77,65	72,71	30	50	95	Sedang
10	82,71	72,26	20	50	51	Sedang
11	77,68	64,76	10	96	100	Sedang
12	77,67	77,07	30	83	99	Sedang
13	81,21	76,83	20	81	84	Sedang
14	70,43	75,04	10	97	72	Sedang
15	71,38	73,36	30	74	66	Sedang
16	77,19	65,09	10	89	75	Sedang

17	74,94	72,06	40	94	57	Sedang
18	81,57	72,6	40	50	78	Sedang
19	75,46	69,38	40	65	75	Sedang
20	72,94	73,87	20	88	59	Sedang
21	87,33	77,83	10	54	75	Sedang
22	78,87	88,2	40	71	83	Sedang
23	80,34	76,22	20	78	100	Sedang
24	72,88	76,8	40	52	90	Sedang
25	77,28	74,48	40	61	56	Sedang
26	80,55	61,57	40	75	53	Sedang
27	74,25	74,81	20	65	99	Sedang
28	81,88	75,42	20	100	94	Sedang
29	77	92,24	40	86	60	Sedang
30	78,54	73,65	20	71	78	Sedang
31	76,99	77,11	10	78	85	Sedang
32	89,26	74,76	30	63	74	Sedang
33	79,93	66,82	40	77	70	Sedang
34	74,71	83	30	54	85	Sedang
35	84,11	80,26	30	96	59	Sedang
36	73,9	80,54	10	98	86	Sedang
37	81,04	68,63	30	79	58	Sedang
38	70,2	84,82	40	95	73	Sedang
39	73,36	65,19	10	54	84	Sedang
40	80,98	79,11	30	61	98	Sedang
41	83,69	90,33	40	65	84	Sedang
42	80,86	68,07	30	75	97	Sedang
43	79,42	71,04	30	75	85	Sedang
44	78,49	75,7	30	97	67	Sedang
45	72,61	71,48	20	70	98	Sedang
46	76,4	64,15	20	88	88	Sedang
47	77,7	75,48	40	85	81	Sedang
48	85,29	67,56	40	82	73	Sedang
49	81,72	78,32	40	79	72	Sedang
50	71,18	68,56	40	86	81	Sedang
51	81,62	85,85	30	72	86	Sedang
52	78,07	69,52	30	59	61	Sedang
53	76,62	72,75	30	54	98	Tinggi
54	83,06	80,69	30	85	62	Tinggi
55	85,15	66,38	30	83	72	Tinggi
56	84,66	76,59	30	80	74	Tinggi
57	75,8	84,15	40	59	84	Tinggi
58	78,45	63,75	20	68	90	Tinggi
59	81,66	76,29	20	81	79	Tinggi

60	84,88	76,82	10	50	66	Tinggi
61	77,6	80,47	30	54	98	Tinggi
62	79,07	66,34	10	94	69	Tinggi
63	74,47	65,76	20	53	97	Tinggi
64	74,02	78,65	30	65	74	Tinggi
65	84,06	77,08	20	73	71	Tinggi
66	86,78	76,75	30	65	62	Tinggi
67	79,64	77,43	10	51	68	Tinggi
68	85,02	70,24	10	98	98	Tinggi
69	81,81	76,63	40	77	85	Tinggi
70	76,77	77,05	20	81	61	Tinggi
71	81,81	70	10	76	90	Tinggi
72	87,69	88,06	30	69	68	Tinggi
73	79,82	78,32	30	73	61	Rendah
74	87,82	66,66	20	61	58	Rendah
75	66,9	79,6	30	99	56	Rendah
76	84,11	68,18	10	84	77	Rendah
77	80,44	80,51	10	82	63	Rendah
78	78,5	83,11	30	82	80	Rendah
79	80,46	69,26	30	100	68	Rendah
80	70,06	81,74	30	92	96	Rendah
81	78,9	77,89	30	86	65	Rendah
82	81,79	80,75	40	61	54	Rendah
83	87,39	88,28	30	52	84	Rendah
84	77,41	73,28	20	50	61	Rendah
85	75,96	69,72	30	82	74	Rendah

Berdasarkan hasil prediksi menggunakan model Backpropagation, sebanyak 61,18% mahasiswa diklasifikasikan ke dalam kategori *Sedang*, 23,53% ke dalam kategori *Tinggi*, dan 15,29% ke dalam kategori *Rendah*. Pola distribusi ini mengindikasikan bahwa sebagian besar mahasiswa memiliki capaian akademik pada tingkat menengah, yang mencerminkan stabilitas perilaku belajar meskipun masih terdapat ruang untuk peningkatan menuju kategori lebih tinggi.

Secara performa, model Backpropagation yang dikembangkan dalam penelitian ini mencapai tingkat akurasi sebesar 91,17% dengan nilai Mean Squared Error (MSE) sebesar 0,2359. Kinerja ini menunjukkan tingkat prediksi yang kompetitif bila dibandingkan dengan metode lain yang telah digunakan dalam studi sebelumnya. Sebagai contoh, penelitian oleh Rofilde Hasudungan dan Wawan Joko Pranoto [9] menerapkan algoritma Naïve Bayes untuk prediksi prestasi mahasiswa dan memperoleh akurasi sebesar 77,5%, sementara penelitian oleh Prestian Ramadhan, Yuhandri dan Jhon Veri [10] menggunakan algoritma Decision Tree C4.5 dan mencatatkan akurasi sebesar 91,67%. Perbandingan ini menunjukkan bahwa Backpropagation mampu bersaing secara langsung dengan pendekatan klasifikasi konvensional, bahkan mendekati akurasi tertinggi pada Decision Tree C4.5.

Di sisi lain, pendekatan K-Means Clustering yang digunakan oleh Shefia Natalia Br Sembiring, Hendryan Winata, Sri Kusnasari [11] dalam pengelompokan prestasi siswa berhasil mengidentifikasi pola akademik siswa berdasarkan karakteristik data. Namun, karena bersifat *unsupervised learning*, metode ini tidak secara eksplisit mengklasifikasikan data ke dalam label aktual dan tidak memungkinkan evaluasi performa menggunakan metrik seperti akurasi, precision, atau recall.

Dengan demikian, penggunaan Backpropagation dalam penelitian ini tidak hanya unggul dalam hal akurasi, tetapi juga memiliki kelebihan metodologis dalam mengklasifikasikan data secara terarah berdasarkan perilaku belajar. Temuan ini memperkuat posisi Backpropagation sebagai metode prediktif yang

adaptif dalam konteks pemetaan prestasi akademik mahasiswa, serta memberikan kontribusi nyata terhadap pengembangan sistem pendukung keputusan akademik berbasis data.

5. Kesimpulan

Penelitian ini telah berhasil mengembangkan model prediksi prestasi mahasiswa dengan memanfaatkan algoritma Backpropagation berbasis data perilaku belajar. Lima variabel utama digunakan sebagai parameter input dalam model, meliputi persentase kehadiran, nilai tugas, persentase keterlambatan pengumpulan tugas, nilai Ujian Tengah Semester (UTS), dan nilai Ujian Akhir Semester (UAS), yang diperoleh dari 85 mahasiswa Program Studi Informatika Institut Teknologi Alberth Foenay (ITAF) Kupang angkatan 2024. Hasil pelatihan menunjukkan bahwa model Backpropagation mampu mengklasifikasikan kategori prestasi akademik mahasiswa dengan tingkat akurasi sebesar 91,17% dan nilai Mean Squared Error (MSE) sebesar 0,2359, menandakan tingkat ketepatan prediksi yang tinggi. Distribusi prediksi menunjukkan dominasi pada kategori *Sedang*, disusul oleh *Tinggi* dan *Rendah*, yang secara umum mencerminkan profil perilaku belajar mahasiswa pada populasi yang diamati. Dibandingkan dengan pendekatan klasifikasi lain seperti Naïve Bayes (77,5%) dan Decision Tree C4.5 (91,67%) yang telah diimplementasikan pada penelitian terdahulu, model Backpropagation menunjukkan kinerja yang kompetitif dan adaptif terhadap data dengan karakteristik non-linear. Hal ini menunjukkan bahwa Backpropagation merupakan pendekatan alternatif yang layak dan dapat diandalkan untuk memetakan capaian akademik berdasarkan data perilaku belajar. Kebaruan dalam penelitian ini terletak pada penggunaan dataset spesifik mahasiswa ITAF Kupang yang belum pernah digunakan dalam penelitian sejenis sebelumnya, serta pada rancangan arsitektur model prediksi yang mengintegrasikan proses normalisasi khusus dan parameter pelatihan yang disesuaikan secara eksperimental. Temuan ini memberikan kontribusi terhadap literatur dalam bidang prediksi berbasis data serta membuka peluang pengembangan sistem pendukung keputusan akademik yang lebih adaptif, khususnya dalam hal identifikasi dini terhadap mahasiswa dengan kecenderungan capaian akademik tertentu.

Daftar Pustaka

- [1] A. Setiawati, Maryana, and I. Permatasari, "Faktor-Faktor Yang Mempengaruhi Prestasi Belajar Mahasiswa Keperawatan," *J. Penelit. Perawat Prof.*, vol. 6, no. 1, pp. 121–130, 2024, doi: <https://doi.org/10.37287/jppp.v6i1.2028>.
- [2] S. L. D. P. Nalim, "Faktor-Faktor Yang Mempengaruhi Prestasi Akademik Mahasiswa," *J. Pendidik.*, vol. 21, no. 1, pp. 1–17, 2020, doi: [10.33830/jp.v21i1.704](https://doi.org/10.33830/jp.v21i1.704).
- [3] E. H. Damanik, E. Irawan, and F. Rizki, "JARINGAN SYARAF TIRUAN UNTUK MEMPREDIKSI NILAI SISWA SMA MENGGUNAKAN BACKPROPAGATION," *JUSIKOM PRIMA (Jurnal Sist. Inf. dan Ilmu Komput. Prima)*, vol. 4, no. 2, pp. 1–7, 2021, doi: <https://doi.org/10.34012/jurnalsisteminformasidanilmukomputer.v4i2>.
- [4] N. Nafi'iyah, R. A. Ahmad, and S. Mujilawati, "Prediksi Nilai Calon Mahasiswa dengan Algoritma Backpropagation (Studi Kasus: Data Kaggle)," *J. Nas. Komputasi dan Teknol. Inf.*, vol. 3, no. 1, pp. 9–17, 2020, doi: [10.32672/jnkti.v3i1.1945](https://doi.org/10.32672/jnkti.v3i1.1945).
- [5] M. Agarwal and B. B. Agarwal, "Predicting Student Academic Performance Using Neural Networks: Analyzing the Impact of Transfer Functions, Momentum and Learning Rate," *Int. J. Exp. Res. Rev.*, vol. 40, no. Special Issue, pp. 56–72, 2024, doi: [10.52756/ijerr.2024.v40spl.005](https://doi.org/10.52756/ijerr.2024.v40spl.005).
- [6] M. Muftikhah and H. Mustafidah, "Prediksi Prestasi Belajar Mahasiswa Berdasarkan Faktor Internal dan Eksternal Menggunakan Jaringan Backpropagation dengan Klasifikasi Fuzzy," *Sainteks*, vol. 21, no. 1, p. 47, 2024, doi: [10.30595/sainteks.v21i1.21590](https://doi.org/10.30595/sainteks.v21i1.21590).
- [7] N. F. Rahmadani, A. Nugroho, and L. S. Haharap, "Prediksi Nilai Mahasiswa Berdasarkan Riwayat Akademik Menggunakan Jaringan Syaraf Tiruan," *J. Multidiscip. Inq. Sci. Technol. Educ. Res.*, vol. 2, no. 1, pp. 31–40, 2025, doi: <https://doi.org/10.32672/mister.v2i1.2327>.
- [8] I. P. B. Arya Pradnyana and I. G. Sunaya, "Peramalan Hasil Studi Terhadap Kehadiran Mahasiswa Menggunakan Metode Backpropagation," *J. Inov. Teknol. dan Edukasi Tek.*, vol. 2, no. 1, pp. 20–26, 2022, doi: [10.17977/um068v2i12022p20-26](https://doi.org/10.17977/um068v2i12022p20-26).
- [9] R. Hasudungan and W. J. Pranoto, "Implementasi Teorema Naïve Bayes Pada Prediksi Prestasi Mahasiswa," *J. Rekayasa Teknol. Inf.*, vol. 5, no. 1, p. 10, 2021, doi: [10.30872/jurti.v5i1.4996](https://doi.org/10.30872/jurti.v5i1.4996).
- [10] P. Ramadhan, Yuhandri, and J. Veri, "Eksplorasi Algoritma Decision Tree untuk Penentuan Siswa Berprestasi," *bit-Tech*, vol. 7, no. 3, pp. 826–833, 2025, doi: [10.32877/bt.v7i3.2210](https://doi.org/10.32877/bt.v7i3.2210).
- [11] S. N. Br Sembiring, H. Winata, and S. Kusnasari, "Pengelompokan Prestasi Siswa Menggunakan Algoritma K-Means," *J. Sist. Inf. Triguna Dharma (JURSI TGD)*, vol. 1, no. 1, p. 31, 2022, doi: [10.53513/jursi.v1i1.4784](https://doi.org/10.53513/jursi.v1i1.4784).
- [12] M. Iqbal Ulumando, "Prediksi Hasil Produksi Tanaman Kopi Di Wilayah Ntt Dengan Menggunakan Backpropagation," *J. Agroteknologi Pertan. Publ. Ris. Ilm.*, vol. 4, no. 2, pp. 28–45, 2022, doi: [10.30605/agroteknologi.v4i2.2022.28-45](https://doi.org/10.30605/agroteknologi.v4i2.2022.28-45).

- 10.55542/jappri.v4i2.391.
- [13] M. Iqbal Ulumando, "PREDIKSI HASIL PRODUKSI JAMBU METE DI WILAYAH PROVINSI NUSA TENGGARA TIMUR DENGAN MENGGUNAKAN ALGORITMA BACKPROPAGATION," *J. Sist. Inf. dan Sist. Komput.*, vol. 10, no. 1, pp. 124–138, 2025, doi: <https://doi.org/10.51717/simkom.v10i1.781>.
- [14] Y. Muamar and A. Muhajirin, "Penerapan Jaringan Saraf Tiruan Dengan Metode Backpropagation Untuk Memprediksi Tingkat Kelulusan Mahasiswa Perguruan Tinggi," *Digit. Transform. Technol.*, vol. 4, no. 1, pp. 214–224, 2024, doi: 10.47709/digitech.v4i1.3810.
- [15] Y. Baashar *et al.*, "Toward Predicting Student's Academic Performance Using Artificial Neural Networks (ANNs)," *Appl. Sci.*, vol. 12, no. 3, pp. 1–16, 2022, doi: 10.3390/app12031289.
- [16] Rifdah Syahputri, Alwi Andika Panggabean, and Lailan Sofinah Harahap, "Penerapan Algoritma Backpropagation dalam Memprediksi Kemenangan dalam Bermain Mobile Legends," *Neptunus J. Ilmu Komput. Dan Teknol. Inf.*, vol. 2, no. 4, pp. 216–228, 2024, doi: 10.61132/neptunus.v2i4.470.
- [17] G. W. N. Hazlita, Sarjon Defit, "Backpropagation Neural Network Untuk Prediksi Kebutuhan Pemakaian Obat (Kasus Di RSUD dr. Adnaan WD)," *J. Ris. Sist. Inf. Dan Tek. Inform.*, vol. 9, no. 1, pp. 300–309, 2024, doi: <http://dx.doi.org/10.30645/jurasik.v9i1.736>.
- [18] Syaharuddin, Fatmawati, and H. Suprajitno, "Investigations on Impact of Feature Normalization Techniques for Prediction of Hydro-Climatology Data Using Neural Network Backpropagation with Three Layer Hidden," *Int. J. Sustain. Dev. Plan.*, vol. 17, no. 7, pp. 2069–2074, 2022, doi: 10.18280/ijstdp.170707.
- [19] N. Cahyani, R. Irsyada, and R. Mahmuda, "Penerapan Algoritma Neural Network untuk Klasifikasi Diabetes Mellitus: Perbandingan Backpropagation dan Resilient Backpropagation," *Digit. Transform. Technol.*, vol. 4, no. 2, pp. 1067–1074, 2025, doi: 10.47709/digitech.v4i2.5208.