

Optimalisasi Prediksi Dalam Kelulusan Berbasis Deep Learning: Perbandingan Kinerja Multi-Layer Perceptron dan Deep Neural Network

Muhammad Iqbal^{1*}, Yumi Novita Dewi², Lisnawanty³, Maisyaroh⁴, Suhardjono⁵

^{1,2,3}Program Studi Informatika, Universitas Bina Sarana Informatika

⁴Program Studi Teknologi Informasi, Universitas Bina Sarana Informatika

⁵Program Studi Sistem Informasi, Universitas Bina Sarana Informatika

*iqbal.mdq@bsi.ac.id

Abstrak

Prediksi kelulusan tepat waktu merupakan salah satu tantangan penting dalam pendidikan, yang bertujuan untuk memodelkan faktor-faktor yang mempengaruhi keberhasilan akademik mahasiswa. Penelitian ini bertujuan untuk membandingkan kinerja dua algoritma Deep Learning, yaitu Deep Neural Networks (DNN) dan Multi-Layer Perceptron (MLP), dalam memprediksi kelulusan tepat waktu mahasiswa. Metodologi yang digunakan melibatkan evaluasi kedua algoritma dengan berbagai metrik performa, termasuk Recall, Accuracy, Precision, AUC, MCC, dan Cohen Kappa. Hasil penelitian menunjukkan bahwa DNN memiliki kemampuan yang lebih baik dalam hal Recall (0.9766), yang menunjukkan kemampuannya dalam menangkap sebagian besar mahasiswa yang lulus tepat waktu, meskipun AUC (0.8625) dan Precision (0.8803) lebih rendah dibandingkan MLP. Sebaliknya, MLP unggul dalam Accuracy (0.8812) dan Precision (0.9037), serta memberikan hasil yang lebih stabil pada MCC dan Cohen Kappa, menunjukkan keseimbangan yang lebih baik antara memprediksi mahasiswa yang lulus tepat waktu dan tidak. Secara keseluruhan, meskipun DNN lebih sensitif dalam menangkap mahasiswa yang lulus tepat waktu, MLP lebih unggul dalam hal keseimbangan antara akurasi dan menghindari kesalahan prediksi. Penelitian ini menyarankan penggunaan MLP jika prioritas utama adalah akurasi dan stabilitas prediksi, sementara DNN cocok digunakan apabila fokus utama adalah menangkap sebanyak mungkin mahasiswa yang lulus tepat waktu.

Kata kunci : Deep Neural Network, Deep Learning, Kelulusan, Mahasiswa, Multi-Layer Perceptron

Abstract

Predicting on-time graduation is one of the significant challenges in education, aiming to model the factors influencing academic success. This study aims to compare the performance of two Deep Learning algorithms, namely Deep Neural Networks (DNN) and Multi-Layer Perceptron (MLP), in predicting on-time graduation. The methodology used involves evaluating both algorithms with various performance metrics, including Recall, Accuracy, Precision, AUC, MCC, and Cohen Kappa. The results show that DNN performs better in terms of Recall (0.9766), indicating its ability to capture most of the students who graduate on time, although its AUC (0.8625) and Precision (0.8803) are lower compared to MLP. On the other hand, MLP excels in Accuracy (0.8812) and Precision (0.9037), providing more stable results for MCC and Cohen Kappa, demonstrating a better balance in predicting students who graduate on time and those who do not. Overall, while DNN is more sensitive in capturing students who graduate on time, MLP performs better in terms of balance between accuracy and minimizing prediction errors. This study suggests using MLP if the primary priority is accuracy and prediction stability, while DNN is more suitable when the main focus is capturing as many students as possible who graduate on time.

Keywords : Deep Neural Network, Deep Learning, Graduation, Multi-Layer Perceptron, Students.

1. Pendahuluan

Sekolah adalah proses belajar mendapatkan ilmu pengetahuan yang bermanfaat untuk masa

depan, sehingga bisa mendapatkan bukti ijazah dalam berbagai tingkatan. Dimulai dari SD, SMP, SMA, sampai ke perguruan tinggi Sarjana.

Kelulusan dalam proses pembelajaran adalah target pencapaian seseorang dalam belajar, menjadi Sarjana khususnya mahasiswa dengan lulus tepat waktu sesuai target pembelajaran, merupakan yang diharapkan bagi mahasiswa. Lulus tepat waktu adalah keinginan mahasiswa, tidak hanya itu lulus tepat waktu adalah keuntungan bagi kedua belah pihak, yaitu mahasiswa dan instansi pendidikan^[1].

Untuk mengetahui proses kelulusan mahasiswa dapat dilakukan dengan membuat sistem perhitungan dengan metode *Deep Learning*, perbandingan kinerja antara *Multi-layer perceptron* dan *Deep Neural Network* yang nantinya dapat digunakan di sebuah Perguruan Tinggi, sehingga mengetahui faktor kelulusan dari setiap mahasiswa yang mengikuti pembelajaran disetiap semesternya. Dengan sistem lulus tepat waktu ini, menjadikan tingkat kelulusan menjadi faktor utama dalam penilaian keberhasilan Perguruan Tinggi. Jika terjadi penurunan kelulusan maka akan berpengaruh juga terhadap penilaian sebuah Perguruan Tinggi, yang bisa saja mengakibatkan penurunan nilai akreditasi pada Perguruan Tinggi tersebut.

Sistem cerdas atau sering disebut sebagai sistem kecerdasan buatan atau *Artificial Intelligence (AI)* digunakan untuk memodelkan perilaku cerdas dan pemikiran kritis yang sebanding dengan manusia^[2]. *Artificial Neural Network* atau yang lebih dikenal dengan ANN, merupakan bagian

dari *Artificial Intelligence*. ANN adalah sebuah metode yang biasa dipakai untuk melakukan klasifikasi atau prediksi^[3]. Sedangkan *Deep Learning (DL)* merupakan sub bagian dari *Machine Learning* yang fokus pada pengembangan sebuah sistem yang mampu belajar sendiri tanpa harus berulang kali diprogram secara manual oleh manusia^[4]. DL menggunakan beberapa lapisan (*layers*) di antara lapisan masukan (*input layer*) dan lapisan keluaran (*output layer*). Arsitektur tersebut dapat digunakan untuk melakukan pemrosesan nonlinier dengan beberapa tahap yang hasilnya dapat digunakan untuk *feature learning* dan klasifikasi pola (*pattern classification*)^[5].

Penelitian yang mengaplikasikan *Genetic Algorithms (GA)* untuk meningkatkan akurasi model *neural network* dalam memprediksi kelulusan mahasiswa^[7]. Penelitian yang memanfaatkan Decision Tree yang diperkaya dengan GA untuk mengklasifikasikan kelulusan mahasiswa^[8]. Penelitian yang menggabungkan *Naive Bayes (NB)* dengan PSO dalam memprediksi kelulusan mahasiswa^[9]. Penelitian yang berfokus pada penggunaan algoritma genetika untuk meningkatkan akurasi dalam prediksi kelulusan^[10]. Serta penelitian yang menggunakan pendekatan Machine Learning untuk menganalisis prediksi kelulusan mahasiswa^[11]. Selain itu, ada juga penelitian yang membahas perbandingan berbagai algoritma

dalam memprediksi waktu kelulusan mahasiswa^[12]. Penelitian dengan mengaplikasikan Decision Tree yang dipadukan dengan PSO untuk prediksi kelulusan mahasiswa^[13]. Penelitian yang menerapkan Support Vector Machine (SVM) dengan PSO untuk memprediksi kelulusan mahasiswa^[14]. Penelitian yang menggunakan Hybrid Optimization dengan Genetic Algorithm (GA) untuk meningkatkan prediksi kelulusan mahasiswa^[15].

Secara umum, langkah-langkah dalam pelatihan algoritma MLP menggunakan *backpropagation* untuk mengubah nilai bobot-bobotnya dalam arah mundur (*backward*). Untuk mendapatkan error ini, tahap *feed-forward* harus dikerjakan terlebih dahulu. Pada saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan sebuah fungsi aktivasi^[16]. Kemudian *Deep Neural Network* yang masih dalam layer pada *Deep Learning*, memprediksi dengan berbasis jaringan saraf, yang dapat digunakan dalam pengambilan keputusan. Sistem kelulusan secara tepat waktu yang dapat diperhitungkan dengan mengklasifikasikan berdasarkan dataset dari data mahasiswa, seperti : Jenis kelamin, Jurusan, Asal SLTA, dan IPK dari setiap semester, sehingga dapat diambil keputusan dari layer tersebut, apakah mahasiswa tersebut bisa dikatakan lulus tepat waktu atau tidak tepat waktu.

Untuk mendapatkan hasil dari kelulusan tepat waktu tersebut maka dilakukan perhitungan dari setiap data layer algoritma *Deep Learning*. Dari hasil perhitungan dengan kinerja *Deep Neural Network* dengan *Multi Layer Perception*, kemudian dibandingkan hasil yang didapatkan, lebih besar mana faktor kelulusan dari kedua kinerja tersebut dengan tujuan untuk memberikan solusi praktis bagi perguruan tinggi dalam memonitor dan meningkatkan tingkat kelulusan mahasiswa dengan akurat dan efisien. Dengan memanfaatkan MLP dan DNN, kami berharap dapat menyarankan algoritma yang diimplementasikan untuk meningkatkan prediksi kelulusan tepat waktu berdasarkan data mahasiswa.

2. Tinjauan Pustaka

2.1. Penelitian Terkait

Penelitian terkait penerapan model algoritma Multi Layer Perceptron (MLP) merupakan salah satu metode deep learning yang efektif untuk permasalahan klasifikasi, dibandingkan metode konvensional lainnya. Hasil penelitian mengungkapkan bahwa kinerja algoritma ini bervariasi, dengan nilai terendah 62,89%, tertinggi 100%, dan rata-rata 91,98%. Berdasarkan nilai tersebut, dapat disimpulkan bahwa MLP memiliki kinerja yang sangat baik dan layak digunakan dalam prediksi serta klasifikasi^[17].

- Penelitian pertama mengintegrasikan Particle Swam Optimization (PSO) dengan Neural Network. Evaluasi kinerja model Neural Network menggunakan aplikasi RapidMiner, diperoleh hasil perbandingan akurasi yang signifikan. Model Neural Network diintegrasikan dengan optimasi algoritma PSO menunjukkan tingkat akurasi sebesar 71,51%. Angka ini secara jelas melampaui model Neural Network yang digunakan tanpa optimasi PSO, yang hanya mencapai akurasi 64,32%. Dengan kata lain, penerapan algoritma PSO efektif dalam meningkatkan akurasi prediksi pada model Neural Network^[18].
- Penelitian kedua mengaplikasikan Artificial Neural Network (ANN) untuk memprediksi kelulusan mahasiswa, dengan algoritma genetika sebagai metode optimasi. Model ANN dioptimasi menggunakan algoritma genetika mencapai akurasi 99,33%, meningkat signifikan dari 71,48% pada model ANN murni, dengan selisih 27,85%. Penelitian ini juga mengintegrasikan data kelulusan mahasiswa tahun 2013 (jenis kelamin, IPK, predikat kelulusan, dan skor TOEFL) untuk memprediksi kelulusan dan keterlambatan kelulusan ^[19] ^[20].
- Pada penelitian ketiga, prediksi kelulusan mahasiswa dilakukan untuk meminimalisir keterlambatan dengan model Decision Tree.

Penelitian ini menggunakan data kelulusan tahun 2013 termasuk atribut jenis kelamin, IPK, predikat kelulusan, dan skor TOEFL. Model Decision Tree yang diimplementasikan dan disimulasikan menggunakan aplikasi Weka berhasil mencapai akurasi 60% dalam memprediksi kelulusan mahasiswa.

- Penelitian selanjutnya adalah prediksi status kelulusan Siswa menggunakan Jaringan Syaraf Tiruan Multi Layer Perceptron (JST MLP) sebagai prediktor status kelulusan siswa. Menggunakan 13 atribut dan kelas target biner (1 untuk lulus tepat waktu, 0 untuk tidak lulus tepat waktu). JST MLP yang diusulkan memiliki tiga lapisan (13 neuron masukan, 12 neuron tersembunyi, 1 neuron keluaran). Dengan 100 epochs pada Python Google Colab, model mencapai akurasi 95%, menunjukkan tingkat prediksi yang baik ^[21].

2.2. Landasan Teori

1. Dataset

Penelitian ini menggunakan dataset riwayat akademik mahasiswa dari perguruan tinggi berupa Data Mahasiswa. Data mahasiswa yang digunakan dalam penelitian ini meliputi variabel-variabel penting seperti Jenis Kelamin, Jurusan, Asal SLTA, dan Indeks Prestasi Kumulatif (IPK) dari setiap semester. Variabel variabel ini akan menjadi input bagi model deep learning untuk mengklasifikasikan status kelulusan mahasiswa,

yaitu apakah mereka lulus tepat waktu atau tidak tepat waktu.

2. Deep Neural Network

Deep Neural Network (DNN) adalah salah satu jenis arsitektur jaringan saraf tiruan (*Artificial Neural Network*) yang terdiri dari banyak lapisan tersembunyi (*hidden layers*) antara lapisan *input* dan *output*. Semakin banyak lapisan yang digunakan, semakin “dalam” jaringan tersebut, itulah mengapa disebut “*deep*”.

3. Multi-Layer Perceptron

Multi-Layer Perceptron (MLP) adalah jenis jaringan saraf tiruan (*Artificial Neural Network*) yang memiliki lebih dari satu lapisan tersembunyi (*hidden layers*). MLP adalah model yang digunakan untuk tugas-tugas klasifikasi atau regresi, dan sangat populer dalam pengenalan pola.

3. Metode Penelitian

3.1. Teknik Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data sekunder berupa rekam jejak akademik mahasiswa dari perguruan tinggi. Data ini mencakup informasi seperti Indeks Prestasi Kumulatif (IPK) setiap semester, riwayat mata kuliah dan nilai, status registrasi, jenis kelamin, jurusan, asal SLTA, dan informasi relevan lainnya yang berkaitan dengan kelulusan mahasiswa. Data akan diperoleh melalui permintaan resmi kepada departemen akademik atau pusat data

universitas, setelah mendapatkan izin yang diperlukan.

3.2. Teknik Analisis Data

Teknik analisis data utama dalam penelitian ini adalah pemodelan prediktif menggunakan *Deep Learning*, yaitu *Multi-Layer Perceptron* (MLP) dan *Deep Neural Network* (DNN). Setelah model dilatih dan dioptimasi, kinerja kedua model akan dianalisis secara komparatif menggunakan metrik evaluasi yang telah ditentukan (Akurasi, Presisi, Recall, AUC, MCC, Cohen's Kappa). Perbandingan ini akan dilakukan untuk mengidentifikasi model mana yang memberikan kinerja terbaik dalam memprediksi kelulusan tepat waktu mahasiswa. Proses penelitian ini melibatkan beberapa tahapan kunci sebagai berikut :

1. Pra-pemrosesan Data

Data mentah yang diperoleh dari perguruan tinggi akan melalui serangkaian tahapan pra-pemrosesan. Ini mencakup penanganan nilai yang hilang (*missing values*) dengan metode imputasi yang sesuai, konversi variabel kategorikal (seperti jenis kelamin, jurusan, dan asal SLTA) menjadi format numerik menggunakan *one-hot encoding*, dan normalisasi data numerik (IPK) menggunakan teknik Min-Max Scaling atau *Standard Scaling* untuk memastikan semua fitur memiliki skala yang seragam dan mencegah dominasi fitur dengan rentang nilai yang lebih besar.

2. Pembagian Dataset

Dataset yang telah bersih akan dibagi menjadi tiga bagian: data pelatihan (training set), data validasi (*validation set*), dan data pengujian (*testing set*) dengan rasio 70% pelatihan, 15% validasi, dan 15% pengujian. Pembagian ini penting untuk melatih model, menyetel *hyperparameter* (menggunakan data validasi), dan mengevaluasi kinerja akhir model secara objektif pada data yang belum pernah dilihat sebelumnya (menggunakan data pengujian). Kami juga mempertimbangkan penggunaan k-fold cross-validation pada tahap pelatihan dan validasi untuk memastikan robustnya model.

3. Desain Arsitektur Model

Penelitian ini membandingkan kinerja dua algoritma *Deep Learning*, yaitu *Deep Neural Networks* (DNN) dan *Multi-Layer Perceptron* (MLP). Proses pelatihan kedua model akan menggunakan algoritma *backpropagation* dengan optimizer Adam dan fungsi *loss Binary Cross-Entropy*.

4. Optimasi Hyperparameter

Untuk mendapatkan kinerja optimal dari kedua model, optimasi *hyperparameter* akan dilakukan. Ini meliputi penyesuaian *learning rate*, *batch size*, dan jumlah *epoch*. Kami akan menggunakan pendekatan *Grid Search* atau *Random Search* untuk mencari kombinasi *hyperparameter* terbaik yang menghasilkan kinerja model paling optimal pada data validasi.

5. Metrik Evaluasi

Kinerja kedua model akan dievaluasi menggunakan berbagai metrik klasifikasi yang relevan :

- a. *Accuracy* (Akurasi): Proporsi prediksi yang benar dari total prediksi. Ini adalah metrik umum namun perlu dilengkapi dengan metrik lain untuk kasus imbalanced dataset.
- b. *Precision* (Presisi): Proporsi prediksi positif yang benar dari total prediksi positif. Penting untuk mengukur seberapa sedikit "*false positives*" (memprediksi lulus tepat waktu padahal tidak).
- c. *Recall* (Sensitivitas): Proporsi prediksi positif yang benar dari total aktual positif. Penting untuk mengukur seberapa baik model dapat mengidentifikasi semua mahasiswa yang sebenarnya lulus tepat waktu.
- d. *AUC* (*Area Under the Receiver Operating Characteristic Curve*): Mengukur kemampuan model dalam membedakan antara kelas positif dan negatif di berbagai ambang batas klasifikasi. Nilai AUC yang lebih tinggi menunjukkan kinerja klasifikasi yang lebih baik.
- e. *MCC* (*Matthews Correlation Coefficient*): Merupakan metrik yang seimbang dan informatif, berguna bahkan untuk imbalanced dataset, karena memperhitungkan true positives, true negatives, false positives, dan false negatives.

f. Cohen's Kappa: Mengukur tingkat kesepakatan antara prediksi model dan label aktual, mempertimbangkan kesepakatan yang mungkin terjadi secara kebetulan. Penggunaan beragam metrik ini penting untuk memberikan gambaran komprehensif tentang kinerja model, terutama dalam konteks prediksi kelulusan yang dapat memiliki implikasi penting bagi mahasiswa dan institusi

g. Perangkat Lunak

Proses pengembangan model, pelatihan, dan evaluasi akan diimplementasikan menggunakan bahasa pemrograman Python dengan bantuan library TensorFlow dan Keras untuk membangun arsitektur Deep Learning, serta Scikit-learn untuk pra-pemrosesan data dan metrik evaluasi.

3.3. Lokasi Penelitian

Penelitian ini akan berfokus pada data rekam jejak mahasiswa di Pontianak, Kalimantan Barat. Pemilihan lokasi ini didasarkan pada aksesibilitas data dan relevansi masalah yang diteliti dengan konteks institusi tersebut..

4. Hasil dan Pembahasan

Pada bagian hasil dan pembahasan ini menyajikan temuan dari penelitian yang dilakukan. Dataset yang digunakan dalam penelitian ini terdiri dari beberapa variabel, di antaranya jenis kelamin, jurusan, asal SLTA, nilai

IPK semester 1 hingga semester 6, serta status kelulusan tepat waktu. Analisis diawali dengan eksplorasi data untuk memahami distribusi dan hubungan antar-variabel, dilanjutkan dengan pembersihan data melalui identifikasi dan penghapusan outlier. Setelah itu, dua model prediksi diterapkan, yaitu *Deep Neural Networks* (DNN) dan *Multi-Layer Perceptron* (MLP), untuk memprediksi kelulusan tepat waktu. Setiap tahapan dilengkapi dengan visualisasi data yang mendukung analisis dan interpretasi hasil yang diperoleh.

1. Dataset Penelitian

Untuk mendukung penelitian, disajikan hasil analisis dataset yang digunakan, dimulai dengan deskripsi umum dataset, dilanjutkan dengan eksplorasi distribusi dan korelasi antar variabel, serta evaluasi performa model prediksi yang diterapkan. Dataset ini mencakup berbagai variabel yang relevan dengan ketepatan waktu kelulusan mahasiswa, data demografis, akademik, dan hasil indeks prestasi kumulatif (IPK) dari semester 1 hingga semester 6. Analisis ini bertujuan untuk memperoleh pemahaman yang komprehensif mengenai pola dan faktor-faktor yang memengaruhi ketepatan waktu kelulusan mahasiswa.

	JENIS KELAMIN	JURUSAN	ASAL SLTA	IPK1	IPK2	IPK3	IPK4	IPK5	IPK6	TEPAT WAKTU
0	1	4	4	2.55	2.61	2.64	2.74	2.97	3.00	YA
1	1	9	3	3.23	3.15	3.07	3.17	3.25	3.17	YA
2	2	1	3	2.73	2.73	2.62	2.64	2.89	3.00	YA
3	1	4	3	2.73	3.10	2.97	3.16	3.30	3.33	YA
4	1	5	2	2.18	2.44	2.11	2.36	2.66	2.57	TIDAK
...
791	1	9	3	2.27	2.60	2.56	1.91	2.32	2.52	TIDAK
792	2	4	1	2.09	2.12	2.24	2.29	2.55	2.82	YA
793	2	4	3	2.18	2.21	2.37	2.64	2.91	3.01	YA
794	2	1	3	3.41	3.40	3.40	3.48	3.50	3.52	YA
795	2	7	3	1.95	2.55	2.58	2.53	2.43	2.60	TIDAK

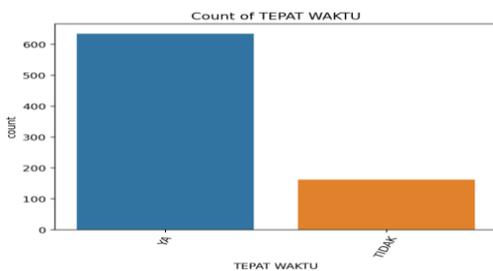
796 rows x 10 columns

Gambar 1. Dataset Penelitian

Pada Gambar 1 menunjukkan dataset awal yang terdiri dari 796 baris dan 10 kolom, yang berisi informasi tentang variabel-variabel seperti jenis kelamin, jurusan, asal SLTA, IPK semester 1 sampai dengan semester 6, dan status kelulusan apakah YA untuk tepat waktu atau TIDAK.

2. Distribusi Dataset

Berdasarkan data pada dataset diatas terhadap label target YA dan Tidak, secara detail pembagiannya pada Gambar 2.



Gambar 2. Distribusi Dataset

Pada gambar 2 Distribusi data pada variabel "TEPAT WAKTU" menunjukkan bahwa mayoritas mahasiswa lulus tepat waktu (label "YA") dengan jumlah lebih dari 600, sementara yang tidak lulus tepat waktu (label "TIDAK") berjumlah kurang dari 200. Distribusi ini memperlihatkan ketidakseimbangan data, yang perlu diperhatikan dalam proses pelatihan model.

3. Korelasi Plot

Merupakan tahap penting dalam analisis data ini adalah visualisasi korelasi antar variabel. Korelasi plot digunakan untuk memahami sejauh mana hubungan linear antara variabel-variabel numerik pada dataset, khususnya nilai IPK semester 1 hingga semester 6 dengan status kelulusan tepat waktu. Identifikasi pola hubungan ini mengungkap potensi kontribusi masing-masing variabel dalam memprediksi kelulusan tepat waktu. Korelasi plot memberikan dasar yang kuat bagi analisis lebih lanjut, termasuk dalam pemilihan variabel input pada pemodelan prediksi.



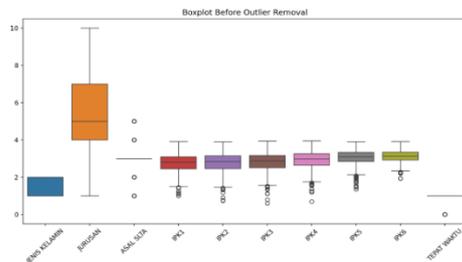
Gambar 3. Korelasi Plot

Pada Gambar 3 Peta korelasi antara variabel menunjukkan bahwa nilai IPK dari semester 1 hingga 6 memiliki korelasi yang cukup tinggi satu sama lain (nilai > 0,7). Sementara itu, variabel "TEPAT WAKTU" menunjukkan korelasi positif moderat dengan IPK (nilai korelasi tertinggi dengan IPK5 = 0,58). Korelasi ini mengindikasikan bahwa IPK memiliki peran signifikan dalam prediksi kelulusan tepat waktu.

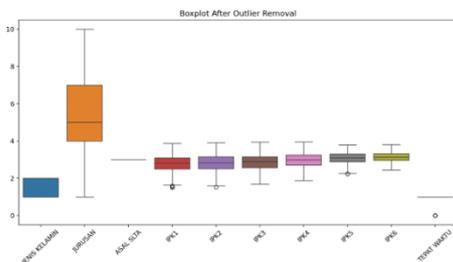
4. Boxplot Outlier

Boxplot digunakan dalam analisis ini untuk memvisualisasikan distribusi dan penyebaran

data pada setiap variabel, serta mengidentifikasi keberadaan outlier. Visualisasi ini mengetahui karakteristik data, seperti median, kuartil, dan nilai ekstrim, yang mempengaruhi keakuratan model prediksi. Dengan membandingkan boxplot sebelum dan sesudah pembersihan outlier, diperoleh pemahaman mengenai dampak proses pembersihan terhadap kualitas dan homogenitas data yang digunakan dalam tahap pemodelan.



Gambar 4. Boxplot Outlier Before Removal



Gambar 5. Boxplot Outlier After Removal

Pada Gambar 4 dan Gambar 5 memperlihatkan visualisasi distribusi nilai dari setiap variabel dalam dataset sebelum dan sesudah penghapusan data outlier. Pada *boxplot before outlier removal*, terlihat bahwa beberapa variabel memiliki nilai ekstrem (outlier) yang ditandai dengan titik-titik di luar batas whisker. Hal ini menunjukkan adanya variabilitas yang cukup besar pada data awal, khususnya pada variabel "JURUSAN" dan beberapa nilai IPK.

Setelah dilakukan pembersihan data (*removal outlier*), *boxplot after outlier removal* memperlihatkan distribusi yang lebih homogen dan simetris, dimana sebagian besar nilai sudah berada dalam rentang normal. Visualisasi ini menegaskan bahwa proses pembersihan data berhasil meminimalisasi outlier, sehingga data menjadi lebih stabil dan representatif. Tahap ini berguna untuk memastikan bahwa data yang digunakan dalam pemodelan prediksi memiliki kualitas yang baik dan tidak terpengaruh oleh nilai-nilai ekstrem yang dapat mengganggu hasil analisis.

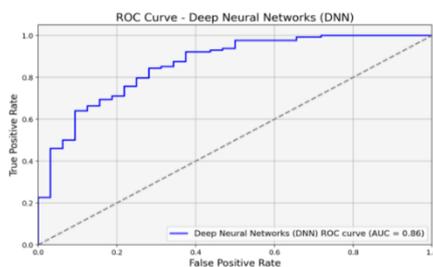
5. Evaluasi Model

Mengevaluasi performa model prediksi kelulusan tepat waktu menggunakan dua metode pemodelan: Deep Neural Networks (DNN) dan Multi-Layer Perceptron (MLP). Metrik evaluasi yang digunakan mencakup akurasi, AUC, recall, precision, F1 score, Cohen Kappa, dan MCC. Hasil evaluasi masing-masing model disajikan pada Tabel 1 berikut:

Tabel 1. Evaluasi Model

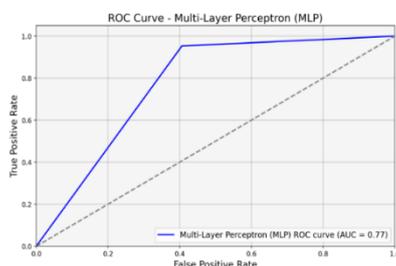
Metrik	Deep Neural Networks (DNN)	Multi-Layer Perceptron (MLP)
Accuracy	0.8750	0.8812
AUC	0.8625	0.7734
Recall	0.9766	0.9531
Precision	0.8803	0.9037
F1 Score	0.9259	0.9278
Kappa	0.5327	0.5957
MCC	0.5637	0.6025

Pada Tabel 1 hasil menunjukkan bahwa model Multi-Layer Perceptron (MLP) memiliki nilai akurasi yang lebih tinggi dibandingkan model DNN, yaitu 0.8812 berbanding 0.8750. Hal ini mengindikasikan bahwa secara keseluruhan, model MLP lebih baik dalam memprediksi ketepatan waktu kelulusan mahasiswa dengan benar dibandingkan DNN. Meskipun DNN menunjukkan AUC yang lebih tinggi, akurasi yang lebih tinggi pada MLP menjadi indikator penting bahwa model ini lebih unggul dalam klasifikasi secara umum.



Gambar 6. Kurva ROC DNN

Pada gambar 6 dan Gambar 7. Perbandingan hasil menunjukkan bahwa DNN (a) memiliki AUC lebih tinggi (0.86), menunjukkan kemampuan yang lebih baik dalam membedakan dua kelas.



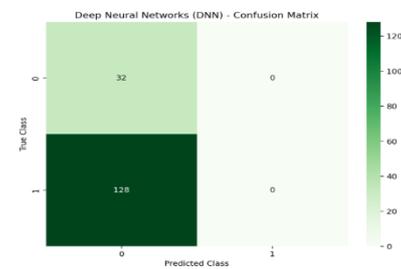
Gambar 7. Kurva ROC MLP

Namun, MLP (b) memiliki akurasi keseluruhan, Cohen Kappa, dan MCC yang sedikit lebih unggul, yang menandakan keseimbangan

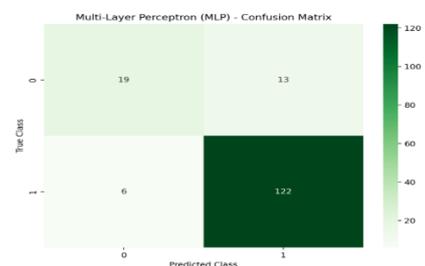
prediksi yang lebih baik. Secara umum, DNN lebih baik untuk deteksi kelas minoritas, sementara MLP unggul untuk akurasi keseluruhan prediksi.

6. Confusion Matrix

Confusion matrix digunakan untuk memberikan gambaran detail mengenai hasil klasifikasi model, terutama dalam membandingkan jumlah prediksi benar dan salah pada masing-masing kelas.



Gambar 8. Confusion Matrix DNN



Gambar 9. Confusion Matrix MLP

Gambar 8 menunjukkan confusion matrix dari dua model prediksi Deep Neural Networks (DNN) dan Gambar 9 Multi-Layer Perceptron (MLP). Pada confusion matrix DNN, terlihat bahwa model hanya memprediksi satu kelas (kelas 0), yaitu 32 prediksi benar pada kelas 0 dan 128 prediksi salah pada kelas 1 yang seharusnya "TEPAT WAKTU". Hal ini menandakan model bias terhadap kelas mayoritas dan tidak mampu mengenali kelas minoritas. Sebaliknya, pada confusion matrix MLP, model menunjukkan

distribusi prediksi yang lebih seimbang. Terdapat 19 prediksi benar pada kelas 0, 122 prediksi benar pada kelas 1, dan hanya sedikit kesalahan (13 prediksi salah untuk kelas 0 dan 6 prediksi salah untuk kelas 1). Hal ini mengindikasikan bahwa model MLP mampu mengenali kedua kelas dengan lebih baik.

5. Kesimpulan

Penelitian ini membandingkan kinerja Deep Neural Networks (DNN) dan Multi-Layer Perceptron (MLP) dalam memprediksi kelulusan tepat waktu mahasiswa. Hasil menunjukkan bahwa DNN unggul dalam Recall (0.9766), menunjukkan sensitivitas tinggi dalam mengenali mahasiswa yang lulus tepat waktu. Namun, MLP menunjukkan kinerja yang lebih seimbang dengan nilai Accuracy (0.8812), Precision (0.9037), serta MCC dan Cohen Kappa yang lebih tinggi. Secara praktis, MLP lebih direkomendasikan bila tujuan utama adalah keseimbangan antara ketepatan prediksi dan mengurangi kesalahan klasifikasi. Sebaliknya, DNN lebih cocok digunakan dalam konteks yang mengutamakan sensitivitas, meskipun berisiko menghasilkan lebih banyak false positives. Penelitian selanjutnya dapat mengeksplorasi model hybrid dengan menggabungkan DNN, MLP, dan algoritma lain seperti Random Forest atau XGBoost untuk meningkatkan akurasi. Selain itu, optimasi hyperparameter lebih lanjut berpotensi meningkatkan kinerja dan efisiensi kedua model.

6. Daftar Pustaka

- [1]. U. R. Habibah and A. Solichin, "Prediksi Kelulusan Mahasiswa Dengan Metode Naive Bayes dan Artificial Neural Network : Studi Kasus Fakultas Teknik UNIS Tangerang," *Fakt Exacta*, Vol 15, No.1, pp. 73-83, 2022.
- [2]. W. H. A. P. Mudjihartono, "Kecerdasan Buatan Dalam Teknologi Kedokteran: Survey Paper," *Konstelasi: Konvergensi Teknologi Dan Sistem Informasi*, vol. 2, no. no.1, 2022.
- [3]. T. P. A. Y. A. M. Shandy, "Perbandingan Model Logistic Regression Dan Artificial Neural Network Pada Prediksi Pembatalan Hotel," *Jurnal Informatika Sunan Kalijaga (JISKA)*, vol. 6, no. no..1, pp. 29-37, 2021.
- [4]. A. O. G. a. O. P. Tedyyana, "Model Design of Intrusion Detection System on Web Server Using Machine Learning Based.,," in *Proceedings of the 11th International Applied Business and Engineering Conference, ABEC 2023*, Bengkalis, Riau, Indonesia, 2023.
- [5]. M. H. Diponegoro, S. S. Kusumawardani and I. Hidayah, "Tinjauan Pustaka Sistematis: Implementasi Metode Deep Learning pada Prediksi Kinerja Murid," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 10, no. no.2, pp. 131-138, 2021.
- [6]. H. Nurdin, Sartini, Sumarna, Y. I. Maulana and V. Riyanto, "Prediction of Student Graduation with the Neural Network Method Based on Particle Swarm Optimization," *Jurnal Sinkron*, vol. 7, no. no.4, pp. 2354-2362, 2023.
- [7]. W. E. Pangesti, I. Ariyati, Priyono, Sugiono and R. Suryadithia, "Utilizing Genetic Algorithms to Enhance Student Graduation Prediction with Neural Networks," *Jurnal Sinkron*, vol. 8, no. no.1, pp. 277-284, 2024.

- [8]. S. Rukiastiandari, L. Rohimah, Aprillia and F. Mutia, "Predicting Graduation Outcomes: Decision Tree Model Enhanced with Genetic Algorithm," *Paradigma*, vol. 26, no. No.1, pp. 1-6, 2024.
- [9]. A. H. Kahfi, T. Prihatin, Yudhistira, A. Sudrajat and G. Wijaya, "The Right Steps Towards Graduation: Nb-Pso Smart Combination For Student Graduation Prediction," *Jurnal Teknik Informatik*, vol. 5, no. No.2, pp. 607-614, 2024.
- [10]. Sumarna, I. Nawawi, Suhardjono, H. Sugiarto and D. Yuliandari, "Meningkatkan Akurasi Prediksi Kelulusan Mahasiswa Menggunakan Metode Algoritma Genetika," *Jurnal Informatika*, vol. 16, no. No.2, pp. 243-247, 2024.
- [11]. Ridwansyah, M. Iqbal, H. Destiana, Sugiono and A. Hamid, "Data Mining Berbasis Machine Learning Untuk Analitik Prediktif Dalam Kelulusan," *Semantik*, vol. 10, no. No.2, pp. 1-10, 2024.
- [12]. V. Riyanto, A. Hamid and Ridwansyah, "Prediction of Student Graduation Time Using," *Indonesian Journal of Artificial Intelligence and Data Mining (IJAIMD)*, vol. 2, no. No.1, pp. 1-9, 2019.
- [13]. "Analisis Prediksi Kelulusan Mahasiswa Menggunakan Decision Tree Berbasis Particle," *Jurnal SISFOKOM*, vol. 9, no. No.1, pp. 102-107, 2020.
- [14]. W. Suhardjono, "Prediksi Waktu Kelulusan Mahasiswa Menggunakan Svm Berbasis Pso," *Bianglala*, vol. 7, no. No.2, pp. 97-101, 2019.
- [15]. Ridwansyah, G. Wijaya and J. J. Purnama, "Hybrid Optimization Method Based On Genetic Algorithm For Graduates Students," *Pilar Nusa Mandiri*, vol. 16, no. No.1, pp. 53-58, 2020.
- [16]. D. Pardede, B. Hayadi and Iskandar, "Kajian Literatur Multi Layer Perceptron : Seberapa Baik Performa Algoritma Ini," *Journal of ICT Application and System*, vol. 1, no. no. 2, pp. 23-34, 2022.
- [17]. D. Pardede, B. Herawan Hayadi, and Iskandar, "Kajian Literatur Multi Layer Perceptron: Seberapa Baik Performa Algoritma Ini," *Journal of ICT Application and System*, vol. 1, no. 1, pp. 23-34, 2022.
- [18]. V. K. Bakti, Dairoh, and M. Naufal, "Neural Network dan Particle Swam Optimization untuk Penunjang Keputusan Antipasi Mahasiswa Pra Lulus Bekerja Sesuai Bidang," *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 21, no. 1, pp. 151-158, 2021, doi: 10.30812/matrik.v21i1.1164.
- [19]. Ali, L. Sularto, and K. Kunci, "Optimasi Parameter Artificial Neural Network Menggunakan Algoritma Genetika Untuk Prediksi Kelulusan Mahasiswa," *Jurnal ICT: Information Communication & Technology*, vol. 18, no. 1, pp. 54-59, 2019, [Online]. Available: <https://ejournal.ikmi.ac.id/index.php/jict-ikmi>
- [20]. C. N. Dengen, K. Kusriani, and E. T. Luthfi, "Implementasi Decision Tree Untuk Prediksi Kelulusan Mahasiswa Tepat Waktu," *SISFOTENIKA*, vol. 10, no. 1, p. 1, Jan. 2020, doi: 10.30700/jst.v10i1.484.
- [21]. D. Mardinah and M. Thoriq, "Algoritma Multi Layer Perceptron sebagai Prediksi Kelulusan Mahasiswa Universitas Adzkia Tepat Waktu berdasarkan jenis kelamin, Indeks Prestasi DatSemester, dan Jumlah SKS yang ditempuh," *Jurnal Rekayasa Sistem Komputasi dan Manajemen*, vol. 1, no. 1, 2022, doi: 10.37034/jrskm.v4i4.1