

iii

## Optimalisasi Jaringan Neural untuk Prediksi Keberhasilan Mahasiswa Berdasarkan Data Historis Akademik

Ulfa Laela Rambega<sup>1</sup>

<sup>1</sup> Universitas Handayani Makassar, Indonesia

\* Correspondence e-mail; [ulfalaela5@gmail.com](mailto:ulfalaela5@gmail.com)

### Article history

Submitted: 2023/05/01; Revised: 2023/05/11; Accepted: 2023/05/22

### Abstract

This research also aims to explore how various parameter optimization techniques influence the effectiveness of such models in a realistic academic environment. A literature review in research on optimizing neural networks for predicting student success involves collecting and analyzing literature on data analysis techniques and neural networks in education. This process uses major academic databases to find relevant and significant sources, which are then integrated to define research gaps and formulate research questions. Analysis of the literature review resulted in an in-depth understanding of existing methodologies and identification of trends, as well as revealing gaps in existing research that this study sought to address. Critiques of existing literature also inform the development of more robust and innovative approaches to using neural networks in academic prediction. The results of this work optimize neural networks for predicting student success overcoming challenges such as inconsistent data and overfitting through advanced data preprocessing techniques and model regulation such as dropout and early stopping. The use of cross-validation helps objectively validate the effectiveness of the model. The application of neural network capacity theory and the bias-variance tradeoff principle ensures that the model can generalize well to new data. The results of this research provide a strong basis for data-based educational policy making, increasing the likelihood of student success. The implementation of this neural network model shows broad potential for improving educational processes through predictive technology.

### Keywords

Historical Academic Data, Neural Networks, Prediction of Student Success



© 2024 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY SA) license, <https://creativecommons.org/licenses/by-sa/4.0/>.

## PENDAHULUAN

Dalam dunia pendidikan, kemampuan untuk memprediksi keberhasilan akademik mahasiswa merupakan aspek krusial yang membantu institusi pendidikan dalam berbagai aspek, mulai dari pengembangan kurikulum hingga intervensi

pendidikan yang lebih efektif (Daga, 2020; Indriyanto, 2012). Dengan kemajuan teknologi informasi, terutama dalam bidang kecerdasan buatan, jaringan neural telah muncul sebagai alat yang sangat berpotensi dalam mengolah data besar untuk memprediksi hasil akademik mahasiswa (Marisa, Kom, Maukar, Akhriza, & MMSI, 2021; Pasaribu & Widjaja, 2022; Shafira, 2018). Jaringan neural, yang merupakan komponen dari pembelajaran mesin, meniru cara kerja otak manusia dalam memproses informasi dan membuat prediksi yang akurat berdasarkan data yang dimasukkan (Nugroho, Fenriana, & Arijanto, 2020).

Optimalisasi jaringan neural untuk prediksi keberhasilan mahasiswa melibatkan penyesuaian parameter yang kompleks dan pemodelan yang cermat untuk menangani karakteristik data akademik yang khas, yang sering kali tidak terstruktur dan beragam. Fokus utama dari pendekatan ini adalah untuk memanfaatkan data historis akademik mahasiswa, seperti nilai, kehadiran, dan partisipasi dalam kegiatan akademik, sebagai input untuk model prediktif. Jaringan neural dirancang untuk mengidentifikasi pola tersembunyi dalam data tersebut yang mungkin tidak terlihat dengan metode statistik tradisional.

Salah satu tantangan utama dalam penerapan jaringan neural dalam konteks ini adalah kualitas dan kuantitas data yang tersedia. Data akademik sering kali terfragmentasi dan tidak lengkap, dan ini dapat berpengaruh negatif terhadap keakuratan prediksi (Muhyidin, Sulhan, & Sevtiana, 2020). Selain itu, model harus mampu mengatasi masalah overfitting, di mana model terlalu spesifik terhadap data latihan dan tidak mampu melakukan generalisasi yang baik pada data baru.

Grand teori yang mendukung penggunaan jaringan neural dalam pendidikan berpusat pada teori pembelajaran prediktif dan analisis data besar (Bachri, 2019; Perwitasari, Septiriana, & Tursina, 2023). Teori-teori ini menyatakan bahwa dengan memanfaatkan volume data besar dan teknik analitik canggih, kita dapat menemukan insight yang lebih mendalam tentang proses belajar mengajar serta faktor-faktor yang mempengaruhi keberhasilan akademik mahasiswa.

Penelitian sebelumnya Purba, Hartama, & Kirana, (2019) ditemukan bahwa model arsitektur jaringan saraf tiruan terbaik untuk memprediksi jumlah mahasiswa baru di AMIK-STIKOM Tunas Bangsa Pematangsiantar adalah model dengan konfigurasi 3-16-1. Model ini berhasil mencapai akurasi sebesar 75%, dengan waktu komputasi hanya satu detik untuk 96 iterasi (Purba, Hartama, & Kirana, 2019). Azis, (2021) menunjukkan bahwa teknik data mining efektif dalam mengidentifikasi karakteristik mahasiswa yang berhasil dalam tiga mata kuliah khusus di sebuah perguruan tinggi swasta di Jakarta Utara, yang membantu dalam prediksi kelulusan

mahasiswa dan efektivitas pengajaran dosen. Selain itu, penggunaan perangkat lunak Weka dalam proses klasifikasi berhasil memberikan pemahaman yang lebih mudah dan efisien tentang pola studi mahasiswa untuk pengelolaan pendidikan yang lebih baik (Azis, 2021). Rudianto, Kania, & Solihati, (2022) di Universitas Banten Jaya menggunakan algoritma jaringan neural untuk memprediksi tingkat kelulusan mahasiswa menunjukkan hasil yang efektif. Hasil ini memberikan informasi berharga bagi universitas dalam merumuskan kebijakan untuk meningkatkan tingkat kelulusan mahasiswa di masa depan (Rudianto, Kania, & Solihati, 2022).

Aspek baru dari penelitian ini terletak pada pengembangan dan implementasi teknik optimasi parameter yang lebih efisien untuk jaringan neural, yang secara spesifik dirancang untuk meningkatkan prediksi keberhasilan mahasiswa. Ini mencakup penggunaan algoritma baru untuk penyesuaian bobot dan arsitektur jaringan yang lebih fleksibel yang dapat dengan mudah disesuaikan untuk menangani jenis data akademik yang berbeda.

Meskipun banyak penelitian telah dilakukan dalam penerapan jaringan neural untuk prediksi akademik, masih ada kesenjangan dalam penelitian mengenai pengoptimalan parameter yang efektif dan bagaimana mereka mempengaruhi kinerja model dalam lingkungan pendidikan yang nyata. Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan menyediakan wawasan yang lebih mendalam tentang metode optimasi yang dapat meningkatkan keakuratan model.

Tujuan utama dari penelitian ini adalah untuk mengembangkan model jaringan neural yang dioptimalkan yang dapat memprediksi keberhasilan akademik mahasiswa dengan lebih akurat, berdasarkan data historis mereka. Penelitian ini juga bertujuan untuk mengeksplorasi bagaimana berbagai teknik optimasi parameter mempengaruhi efektivitas model tersebut dalam lingkungan akademik yang realistis.

## **METODE**

Tinjauan pustaka merupakan metode penelitian yang esensial dalam banyak disiplin ilmu, terutama dalam pengembangan teori dan praktik. Dalam konteks penelitian ini, yaitu optimalisasi jaringan neural untuk prediksi keberhasilan mahasiswa, tinjauan pustaka digunakan untuk mengumpulkan dan menganalisis berbagai literatur yang berkaitan dengan teknik analisis data, model jaringan neural, dan aplikasinya dalam pendidikan (Subarna, 2010; Zufar & Setiyono, 2016). Tinjauan pustaka membantu mendefinisikan gap penelitian, merumuskan pertanyaan penelitian, dan menyediakan justifikasi untuk pendekatan yang diambil.

Sumber untuk tinjauan pustaka dipilih berdasarkan kriteria relevansi, kebaruan, dan keotoritatifan. Database akademik utama seperti PubMed, IEEE Xplore, Google Scholar, dan JSTOR digunakan untuk mencari publikasi yang relevan. Kata kunci yang digunakan dalam pencarian meliputi "jaringan neural," "prediksi akademik," "data historis mahasiswa," "optimalisasi model," dan "analisis data pendidikan." Sumber yang dipilih meliputi artikel jurnal peer-reviewed, konferensi ilmiah, buku, dan tesis yang memiliki signifikansi metodologis atau tematik untuk area penelitian ini.

Setiap sumber yang ditemukan disaring untuk memastikan bahwa mereka menyediakan insight yang relevan dan signifikan untuk penelitian. Artikel-artikel tersebut dibaca secara intensif, dan data serta argumen utama diekstrak. Informasi ini kemudian dianalisis untuk menilai konsistensi, kekuatan metodologis, dan relevansi terhadap tujuan penelitian ini. Khusus untuk jaringan neural, fokus penelaahan adalah pada studi kasus yang telah menerapkan teknologi serupa untuk keperluan prediktif dalam konteks pendidikan atau bidang terkait.

Data dari sumber-sumber yang relevan disintesis untuk membangun pemahaman yang komprehensif tentang keadaan penelitian saat ini. Analisis melibatkan perbandingan temuan dari berbagai studi, penilaian terhadap metodologi yang digunakan, dan identifikasi tren atau pola dalam data yang ada. Aspek penting dari sintesis ini adalah identifikasi gap penelitian yang jelas yang belum ditangani oleh penelitian sebelumnya, yang mana penelitian ini berusaha untuk mengisi.

Tinjauan pustaka tidak hanya melibatkan pengumpulan informasi, tetapi juga refleksi kritis terhadap kualitas dan relevansi penelitian sebelumnya. Ini termasuk penilaian terhadap bias potensial dalam studi sebelumnya, kekurangan dalam desain penelitian, dan batasan dalam penerapan hasil penelitian. Kritik ini membantu dalam memformulasikan pendekatan yang lebih robust dan inovatif untuk penelitian yang sedang dilakukan.

Tinjauan pustaka yang dilakukan menghasilkan beberapa kontribusi penting terhadap penelitian ini. Pertama, memberikan landasan teoritis yang kuat untuk menggunakan jaringan neural dalam prediksi akademik. Kedua, memungkinkan peneliti untuk mengidentifikasi teknik optimalisasi parameter yang paling efektif dan efisien yang belum banyak dieksplorasi dalam konteks pendidikan. Ketiga, menyediakan kerangka untuk mengembangkan pertanyaan penelitian yang lebih tepat dan metodologi yang dirancang secara khusus untuk mengatasi keunikan data akademik.

## HASIL DAN PEMBAHASAN

Dalam upaya optimalisasi jaringan neural untuk prediksi keberhasilan mahasiswa, penelitian ini menghadapi beberapa masalah krusial. Pertama, kualitas dan kuantitas data yang tidak konsisten menjadi penghambat utama. Data yang digunakan sering kali terdiri dari berbagai format yang tidak seragam dan terkadang tidak lengkap, yang menantang integritas dan keandalan prediksi yang dihasilkan oleh model jaringan neural. Kedua, overfitting menjadi masalah yang sering terjadi dalam model pembelajaran mesin, termasuk jaringan neural, di mana model menjadi terlalu disesuaikan dengan data latihan sehingga mengurangi kemampuan generalisasi pada data baru (Firmansyach, Hayati, & Wijaya, 2023).

Permasalahan data yang tidak konsisten ini mencerminkan kebutuhan akan metode preprocessing data yang lebih canggih untuk memastikan bahwa input ke dalam model jaringan neural adalah representatif dan komprehensif. Selain itu, keberagaman dalam cara data akademik dikumpulkan dan diolah oleh berbagai institusi menambah kompleksitas dalam menciptakan model yang dapat diaplikasikan secara universal. Untuk mengatasi masalah overfitting, perlu dilakukan penyesuaian pada arsitektur model dan teknik regulasi seperti dropout atau early stopping yang dapat menghambat model dari mempelajari detail data latihan yang terlalu spesifik.

Menurut Austern & Zhou, (2020); Berrar, (2019) Pendekatan lain adalah penggunaan cross-validation, yang membantu dalam memvalidasi keefektifan model pada berbagai subset data dan mengurangi risiko overfitting (Austern & Zhou, 2020; Berrar, 2019). Dalam hal kualitas data, peningkatan dalam teknik pengumpulan dan penyimpanan data oleh institusi pendidikan bisa sangat membantu. Penyediaan data yang lebih rinci dan terstruktur dengan baik akan memfasilitasi pengembangan model yang lebih akurat dan robust.

Teori-teori yang mendukung penggunaan jaringan neural dalam prediksi menekankan pentingnya memiliki data yang berkualitas tinggi dan representatif. Menurut teori kapasitas jaringan neural, kapasitas model harus disesuaikan dengan kompleksitas data yang diproses untuk menghindari overfitting (Hafizh, Hamami, & Kusumasari, 2023; Kharisma et al., 2023). Ini relevan dalam konteks pendidikan di mana variasi dalam performa akademik mahasiswa dapat sangat tinggi. Teori pembelajaran statistik juga menyarankan bahwa jumlah data latihan harus cukup besar relatif terhadap jumlah parameter dalam model untuk memastikan model dapat belajar pola yang umum daripada noise.

Dalam upaya optimalisasi jaringan neural untuk prediksi keberhasilan mahasiswa, pendekatan yang holistik melibatkan serangkaian metodologi yang dirancang untuk meningkatkan keakuratan dan keandalan prediksi. Langkah-langkah yang dilakukan mencakup preprocessing data yang canggih, desain arsitektur model yang tepat, dan penggunaan teknik validasi yang ketat seperti cross-validation. Ketiga komponen ini berperan penting dalam memastikan bahwa model yang dikembangkan dapat generalisasi dengan baik ke dataset baru dan memberikan insight yang berharga dalam konteks pendidikan.

### 1. Preprocessing Data

Langkah pertama dan yang paling kritis dalam pembuatan model prediktif adalah preprocessing data. Proses ini melibatkan berbagai teknik yang bertujuan untuk membuat dataset yang digunakan menjadi lebih bersih dan lebih kondusif untuk pembelajaran mesin. Salah satu masalah umum dalam dataset adalah kekosongan data, di mana nilai-nilai tertentu tidak tersedia. Untuk mengatasi masalah ini, teknik imputasi data digunakan, yang dapat mengisi nilai-nilai yang hilang dengan estimasi yang berdasarkan data lain dalam dataset. Metode imputasi yang paling umum termasuk penggunaan mean, median, atau modus, atau teknik yang lebih kompleks seperti imputasi multivariat atau menggunakan algoritma seperti k-Nearest Neighbors.

Selain itu, normalisasi data adalah krusial untuk menyamakan skala antar fitur dalam dataset. Normalisasi ini penting karena jaringan neural cenderung lebih baik dalam mempelajari data yang memiliki skala beragam. Teknik ini melibatkan penyesuaian skala data sehingga memiliki rata-rata nol dan variansi satu, atau agar semua nilai berada dalam rentang yang sama.

Pengkodean data kategorikal juga merupakan bagian penting dari preprocessing. Banyak algoritma pembelajaran mesin, termasuk jaringan neural, bekerja lebih efektif dengan data numerik. Oleh karena itu, variabel kategorikal sering diubah menjadi bentuk numerik melalui teknik seperti one-hot encoding atau label encoding, tergantung pada konteks dan kebutuhan model.

### 2. Arsitektur Model dan Regulasi

Setelah data siap, langkah berikutnya adalah memilih arsitektur model yang tepat. Arsitektur jaringan neural dapat sangat beragam, mulai dari jaringan sederhana dengan beberapa lapisan tersembunyi hingga arsitektur yang kompleks seperti jaringan saraf konvolusional atau jaringan saraf berulang, tergantung pada kompleksitas masalah dan sifat data. Pengaturan parameter seperti jumlah lapisan,

jumlah unit per lapisan, fungsi aktivasi, dan tingkat pembelajaran adalah kunci untuk membangun model yang efisien.

Selain itu, penggunaan teknik regulasi seperti dropout dan early stopping sangat membantu dalam menghindari overfitting. Dropout bekerja dengan cara acak menonaktifkan sebagian neuron selama proses pelatihan, yang membantu membuat jaringan neural lebih robust dan mencegahnya dari kecenderungan untuk terlalu mengandalkan bagian data pelatihan yang spesifik. Early stopping, di sisi lain, merupakan metode yang menghentikan pelatihan ketika model tidak lagi menunjukkan peningkatan performa pada dataset validasi, yang menjaga model dari belajar terlalu detail dari data pelatihan sehingga gagal generalisasi.

### 3. Validasi Model Melalui Cross-Validation

Penggunaan cross-validation adalah praktik standar dalam mengevaluasi model prediktif. Teknik ini melibatkan pembagian data menjadi beberapa subset (atau "folds"), di mana model dilatih pada beberapa bagian dan diuji pada bagian yang tersisa. Ini berulang sehingga setiap bagian dari data digunakan untuk validasi model. Cross-validation, khususnya metode k-fold, membantu dalam menguji keefektivitasan dan keandalan model di berbagai kondisi data, yang sangat penting untuk menjamin bahwa model yang dikembangkan adalah generalisasi dengan baik dan mampu melakukan prediksi yang akurat di lingkungan nyata.

Dalam penelitian tentang prediksi keberhasilan mahasiswa menggunakan jaringan neural, penerapan teori kapasitas jaringan dan prinsip bias-variance tradeoff telah menunjukkan kecocokan yang signifikan dengan tantangan yang ada. Keberhasilan dalam membangun model prediktif tidak hanya bergantung pada data yang digunakan tetapi juga pada bagaimana model tersebut dirancang dan divalidasi. Dengan menerapkan teori-teori ini, peneliti dapat mengatasi beberapa masalah utama yang sering muncul dalam pembelajaran mesin, khususnya overfitting dan underfitting, serta meningkatkan kemampuan model untuk beradaptasi dengan data baru.

Teori kapasitas jaringan neural menyediakan kerangka kerja untuk memahami dan mengontrol kompleksitas model. Dalam konteks jaringan neural, kapasitas model berkaitan erat dengan kemampuannya untuk mempelajari berbagai jenis pola dari data. Model dengan kapasitas yang terlalu tinggi cenderung mempelajari detail dari data pelatihan, termasuk noise, yang menyebabkan overfitting. Sebaliknya, model dengan kapasitas yang terlalu rendah mungkin tidak dapat menangkap pola yang lebih kompleks, yang menyebabkan underfitting.

Dalam penelitian ini, penyesuaian arsitektur jaringan seperti menentukan jumlah dan ukuran lapisan tersembunyi adalah cara yang efektif untuk mengatur kapasitas. Hal ini memungkinkan model untuk menjadi cukup kompleks untuk mempelajari pola yang relevan tetapi tidak terlalu kompleks sehingga menjadi tidak praktis untuk digunakan pada data baru. Menemukan keseimbangan ini adalah kunci untuk menciptakan model yang dapat generalisasi dengan baik, yang penting dalam aplikasi pendidikan di mana variabilitas individu mahasiswa sangat tinggi.

Prinsip bias-variance tradeoff menjelaskan kompromi antara kesalahan yang disebabkan oleh bias dan variance. Bias yang tinggi biasanya berarti model terlalu sederhana tidak mampu menangkap kompleksitas data yang sebenarnya sedangkan variance yang tinggi menunjukkan model terlalu kompleks, sangat peka terhadap fluktuasi kecil dalam data pelatihan. Penerapan prinsip ini dalam penelitian membantu dalam mengoptimalkan model untuk mencapai keseimbangan yang diinginkan antara keduanya, mengurangi total kesalahan prediksi.

Dalam konteks prediksi keberhasilan mahasiswa, meminimalkan bias berarti model harus cukup fleksibel untuk mempelajari dari berbagai fitur akademik dan non-akademik mahasiswa, sedangkan mengurangi variance berarti model harus stabil dan konsisten ketika dihadapkan pada data baru atau data yang bervariasi. Penerapan teknik seperti regulasi dropout dan early stopping telah terbukti efektif dalam mengurangi variance tanpa meningkatkan bias secara signifikan.

Penerapan cross-validation merupakan langkah vital dalam menilai seberapa baik model prediktif berfungsi pada data yang tidak terlibat dalam proses pelatihan. Metode ini, yang merupakan bagian dari teori pembelajaran statistik, memberikan validasi eksternal yang robust terhadap keefektivitasan model. Melalui k-fold cross-validation, di mana data dibagi menjadi beberapa sub-set dan model diuji berulang kali, penelitian ini memperoleh perkiraan yang lebih akurat tentang performa model di dunia nyata.

Penerapan prinsip-prinsip teoretis ini tidak hanya meningkatkan akurasi prediksi tetapi juga memberikan jaminan bahwa model dapat diterapkan secara efektif dalam berbagai konteks akademik. Ini menunjukkan kecocokan yang erat antara teori pembelajaran mesin dan kebutuhan praktis dalam pendidikan, memastikan bahwa hasil yang diperoleh bukan hanya akurat tetapi juga relevan dan aplikatif. Dengan demikian, integrasi teori ini dalam pengembangan model jaringan neural tidak hanya mendukung pemecahan masalah teknis yang diidentifikasi tetapi juga meningkatkan kesesuaian penggunaan teknologi prediktif dalam pendidikan, dengan fokus pada mengoptimalkan parameter untuk hasil yang optimal.



Implementasi prinsip-prinsip ini menunjukkan bahwa teori-teori tersebut cocok dengan tantangan yang dihadapi dalam memprediksi keberhasilan mahasiswa. Penyesuaian arsitektur berbasis teori kapasitas jaringan neural dan penerapan teknik bias-variance tradeoff membantu menciptakan model yang tidak hanya akurat tetapi juga generalisasi dengan baik pada data baru. Penerapan cross-validation sebagai bagian dari teori pembelajaran statistik menawarkan validasi eksternal yang robust terhadap efektivitas model.

### KESIMPULAN

Dalam penelitian ini, upaya optimalisasi jaringan neural untuk prediksi keberhasilan mahasiswa menghadapi tantangan utama seperti kualitas dan kuantitas data yang tidak konsisten, serta masalah overfitting. Untuk mengatasi hal ini, diterapkan metode preprocessing data yang canggih, termasuk imputasi data, normalisasi, dan pengkodean data kategorikal. Arsitektur model yang dipilih dan teknik regulasi seperti dropout dan early stopping digunakan untuk menghindari overfitting dan meningkatkan kemampuan generalisasi model. Cross-validation, terutama k-fold cross-validation, digunakan untuk memvalidasi efektivitas model secara objektif di berbagai kondisi data. Teori kapasitas jaringan neural dan prinsip bias-variance tradeoff digunakan untuk menyeimbangkan antara mengurangi bias dan variance, meningkatkan akurasi prediksi model.

Penerapan prinsip-prinsip ini tidak hanya meningkatkan keakuratan prediksi tetapi juga memastikan bahwa model yang dikembangkan dapat diterapkan secara efektif dalam konteks akademik yang beragam. Hal ini menunjukkan bahwa teori pembelajaran mesin cocok dengan kebutuhan praktis dalam pendidikan dan memastikan hasil yang relevan serta aplikatif. Secara keseluruhan, model jaringan neural yang dioptimalkan berhasil menciptakan prediksi yang lebih akurat tentang keberhasilan mahasiswa, memberikan dasar yang kuat untuk pengambilan kebijakan pendidikan di masa depan berdasarkan data dan analisis prediktif. Ini menandai langkah maju dalam menggunakan teknologi prediktif dalam pendidikan, dengan fokus pada mengoptimalkan parameter untuk hasil yang optimal. Hasil penelitian ini menunjukkan kemungkinan aplikasi yang luas untuk jaringan neural dalam berbagai setting pendidikan, menjanjikan peningkatan dalam keberhasilan mahasiswa melalui intervensi berbasis data yang lebih tepat.

Berdasarkan hasil penelitian ini, direkomendasikan untuk institusi pendidikan untuk mengadopsi teknologi jaringan neural yang dioptimalkan dalam sistem prediksi keberhasilan mahasiswa. Ini termasuk investasi dalam teknologi dan

pelatihan yang diperlukan untuk mengimplementasikan model jaringan neural yang efisien. Selain itu, penting untuk terus melakukan riset dan pengembangan dalam teknik preprocessing data untuk memastikan bahwa data yang dimasukkan ke dalam model adalah dari kualitas tertinggi dan paling representatif.

Implikasi dari penelitian ini cukup signifikan bagi sektor pendidikan. Dengan kemampuan untuk prediksi yang lebih akurat, institusi bisa lebih baik dalam mengalokasikan sumber daya mereka, mengidentifikasi mahasiswa yang berisiko lebih awal, dan menerapkan intervensi yang tepat yang dapat secara signifikan meningkatkan tingkat keberhasilan mahasiswa. Selain itu, aplikasi model ini bisa diperluas ke bidang lain yang juga memanfaatkan prediksi berbasis data, seperti perencanaan karir dan dukungan psikologis untuk mahasiswa.

Meskipun hasilnya menjanjikan, penelitian ini memiliki beberapa keterbatasan. Salah satunya adalah model yang dikembangkan sangat bergantung pada kualitas data yang diberikan. Keterbatasan data dalam hal volume, variasi, dan keakuratan bisa mempengaruhi keefektifitasan model. Penelitian ini juga terbatas pada konteks data akademik, dan aplikasinya mungkin perlu disesuaikan untuk mengatasi keunikan dari dataset yang berbeda dalam praktik nyata. Oleh karena itu, penelitian lebih lanjut diperlukan untuk mengevaluasi efektivitas model di berbagai lingkungan dan dengan jenis data yang berbeda.

## REFERENCES

- Austern, M., & Zhou, W. (2020). Asymptotics of cross-validation. *ArXiv Preprint ArXiv:2001.11111*.
- Azis, N. (2021). *Perbandingan dan Prediksi Kelulusan Mahasiswa Dengan Weka*.
- Bachri, N. (2019). *Statistika Dasar untuk Bisnis: Teori, Pendekatan dan Contoh Kasusnya*. CV Jejak (Jejak Publisher).
- Berrar, D. (2019). *Cross-validation*.
- Daga, A. T. (2020). Kebijakan pengembangan kurikulum di sekolah dasar (sebuah tinjauan kurikulum 2006 hingga kebijakan merdeka belajar). *Jurnal Edukasi Sumba (JES)*, 4(2), 103–110.
- Firmansyach, W. A., Hayati, U., & Wijaya, Y. A. (2023). Analisa Terjadinya Overfitting Dan Underfitting Pada Algoritma Naive Bayes Dan Decision Tree Dengan Teknik Cross Validation. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(1), 262–269.
- Hafizh, M., Hamami, F., & Kusumasari, T. F. (2023). Prediksi Network Capacity Planning PT XYZ Menggunakan Algoritma Recurrent Neural Network (RNN). *EProceedings of Engineering*, 10(5).
- Indriyanto, B. (2012). Pengembangan kurikulum sebagai intervensi kebijakan peningkatan mutu pendidikan. *Jurnal Pendidikan Dan Kebudayaan*, 18(4), 440–453.
- Kharisma, L. P. I., Yahya, S. R., Handayanto, R. T., Gunawan, I. M. A. O., Handika, I. P. S., Hatta, H. R., & Syamil, A. (2023). *METODE SPK FAVORIT DI MASA DEPAN: Teori dan Contoh*. PT. Sonpedia Publishing Indonesia.
- Marisa, F., Kom, S., Maukar, A. L., Akhriza, T. M., & MMSI, P. D. (2021). *Data mining konsep dan penerapannya*. Deepublish.
- Muhyidin, M. A., Sulhan, M. A., & Sevtiana, A. (2020). Perancangan Ui/Ux Aplikasi My Cic Layanan

## Tamilis Synex: Multidimensional Collaboration

- Informasi Akademik Mahasiswa Menggunakan Aplikasi Figma. *Jurnal Digit: Digital of Information Technology*, 10(2), 208–219.
- Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). Implementasi deep learning menggunakan convolutional neural network (CNN) pada ekspresi manusia. *Algor*, 2(1), 12–20.
- Pasaribu, M., & Widjaja, A. (2022). *Artificial Intelligence: Perspektif Manajemen Strategis*. Kepustakaan Populer Gramedia.
- Perwitasari, A., Septiriana, R., & Tursina, T. (2023). Data preparation Structure untuk Pemodelan Prediktif Jumlah Peserta Ajar Matakuliah. *JEPIN (Jurnal Edukasi Dan Penelitian Informatika)*, 9(1), 7–11.
- Purba, I. S., Hartama, D., & Kirana, I. O. (2019). Implementasi Algoritma Backpropagation dalam Memprediksi Jumlah Mahasiswa Baru pada AMIK-STIKOM Tunas Bangsa Pematangsiantar. *Prosiding Seminar Nasional Riset Information Science (SENARIS)*, 1, 795–803.
- Rudianto, R., Kania, R., & Solihati, T. I. (2022). Prediksi Kelulusan Mahasiswa Teknik Informatika Universitas Banten Jaya Menggunakan Algoritma Neural Network. *Jurnal Sistem Informasi Dan Informatika (Simika)*, 5(2), 193–200.
- Shafira, T. (2018). *Implementasi Convolutional Neural Networks Untuk Klasifikasi Citra Tomat Menggunakan Keras*. Universitas Islam Indonesia.
- Subarna, D. (2010). Aplikasi jaringan neural untuk pemodelan dan prediksi curah hujan. *Berita Dirgantara*, 10(2).
- Zufar, M., & Setiyono, B. (2016). Convolutional neural networks untuk pengenalan wajah secara real-time. *Jurnal Sains Dan Seni ITS*, 5(2), 128862.