

PENDEKATAN DEEP NEURAL NETWORK UNTUK KLASIFIKASI KELAYAKAN PENERIMA BANTUAN SOSIAL: STUDI KASUS PENARGETAN SOSIAL PADA TINGKAT DESA

Selfira Ayu Safitri^{1*}, Muhammad Faisal², Desi Anggreani³

¹Program Studi Informatika, Fakultas Teknik, Universitas Muhammadiyah Makassar, Indonesia

105841104122@student.unismuh.ac.id, muhfaisal@unismuh.ac.id,

desianggreani@unismuh.ac.id

* Corresponding Author

Info Article

Submission : 25-08-2026
Review : 01-09-2026
Revised : 07-09-2026
Accepted : 12-09-2026
Published : 20-09-2026

Keywords:

Bantuan Sosial, Klasifikasi
Kelayakan, Deep Neural
Network, Penargetan Bantuan
Sosial, Prediksi Kemiskinan.

Abstrak

*Bantuan sosial merupakan program pemerintah yang ditujukan untuk mendukung masyarakat yang memenuhi kriteria sosial ekonomi tertentu. Identifikasi penerima yang tepat sangat penting untuk meminimalkan kesalahan penargetan dan memastikan bantuan diberikan kepada rumah tangga yang benar-benar membutuhkan. Pendekatan klasifikasi konvensional memiliki keterbatasan dalam menangkap hubungan yang kompleks dan nonlinier antar karakteristik sosial ekonomi rumah tangga. Oleh karena itu, penelitian ini menerapkan *Deep Neural Network* (DNN) untuk mengklasifikasikan kelayakan penerima bantuan sosial berdasarkan karakteristik sosial ekonomi rumah tangga di Desa Parigi serta mengevaluasi kinerja klasifikasinya. Data diperoleh dari Pemerintah Desa Parigi dan diproses melalui tahapan pembersihan data, pemeriksaan nilai yang hilang, pelabelan, normalisasi, pembagian data, pelatihan model, dan pengujian. Dataset dibagi menjadi data pelatihan dan data pengujian dengan rasio 80:20. DNN dipilih karena arsitektur berlapisnya mampu mempelajari hubungan nonlinier antarvariabel masukan sehingga sesuai untuk memodelkan pola kompleks pada data sosial ekonomi rumah tangga. Hasil evaluasi berdasarkan confusion matrix menunjukkan nilai akurasi sebesar 95,24%, presisi sebesar 92%, recall sebesar 100%, dan F1-score sebesar 95,83%. Hasil tersebut menunjukkan bahwa model DNN memiliki kinerja klasifikasi yang baik dalam mengidentifikasi penerima bantuan sosial yang layak dan tidak layak. Temuan penelitian menunjukkan bahwa DNN dapat digunakan sebagai pendekatan pendukung keputusan berbasis data untuk membantu analisis dan identifikasi penerima bantuan sosial pada tingkat lokal.*

How to Cite : Safitri, S. A., Faisal, M., Anggreani, D. (2026) . Pendekatan Deep Neural Network Untuk Klasifikasi Kelayakan Penerima Bantuan Sosial: Studi Kasus Penargetan Bantuan Sosial Di Desa Parigi. Journal of Computer Science and Information Technology (JCSIT), 3(4), 450-463.

DOI : 10.70248/jcsit.v3i4.4623

This is an open access article under <https://creativecommons.org/licenses/by/4.0/>
Copyright© 2026 by Author. Published by Yayasan Nuraini Ibrahim Mandiri



PENDAHULUAN

Kemiskinan merupakan salah satu persoalan pembangunan yang membutuhkan intervensi kebijakan secara tepat, terutama dalam memastikan bahwa sumber daya pemerintah diterima oleh masyarakat yang benar-benar membutuhkan. Salah satu instrumen penting dalam penanggulangan kemiskinan adalah program bantuan sosial. Ketepatan penargetan menjadi aspek penting karena kesalahan dalam menentukan penerima dapat menyebabkan inclusion error, yaitu bantuan diberikan kepada masyarakat yang kurang atau tidak layak, dan exclusion error, yaitu masyarakat yang

sebenarnya layak tetapi tidak memperoleh bantuan (Dietrich et al., 2024; Grosh et al., 2022).

Penentuan kelayakan penerima bantuan merupakan persoalan yang tidak sederhana karena kondisi sosial ekonomi rumah tangga bersifat multidimensional. Karakteristik seperti jumlah anggota rumah tangga, kondisi tempat tinggal, kepemilikan aset, pendidikan, pekerjaan, dan indikator sosial ekonomi lainnya dapat saling berhubungan dalam menggambarkan kesejahteraan rumah tangga. Pendekatan Proxy Means Test (PMT) telah digunakan untuk melakukan penargetan berdasarkan karakteristik tersebut, tetapi masih dapat menghadapi kesalahan pengukuran dan klasifikasi yang memengaruhi ketepatan penargetan (Gazeaud, 2020; Taufiq & Suyasa, 2023). Keterbatasan tersebut menunjukkan bahwa penentuan kelayakan tidak cukup hanya mempertimbangkan sejumlah indikator secara terpisah, tetapi perlu mempertimbangkan hubungan antarvariabel secara lebih menyeluruh.

Perkembangan Artificial Intelligence (AI), khususnya machine learning, memberikan alternatif dalam mengolah karakteristik sosial ekonomi untuk mendukung proses klasifikasi penerima bantuan. Penelitian terdahulu menunjukkan bahwa machine learning dapat digunakan untuk prediksi kemiskinan dan penargetan bantuan sosial dengan memanfaatkan pola dari data rumah tangga (Usmanova et al., 2022; Aiken et al., 2022). Di Indonesia, Ahmad et al. (2023), Wobcke dan Mariyah (2023), Nazmi et al. (2024), serta Hiola et al. (2026) menunjukkan bahwa berbagai algoritma machine learning dapat digunakan untuk mengklasifikasikan atau memprediksi status penerima bantuan sosial. Namun, pendekatan tersebut umumnya menggunakan algoritma konvensional seperti Decision Tree, Random Forest, Gradient Boosting, regresi, dan Naïve Bayes.

Keterbatasan pendekatan konvensional menjadi relevan ketika hubungan antara karakteristik sosial ekonomi dan status kelayakan bersifat kompleks dan nonlinier. Deep Neural Network (DNN) memiliki kemampuan mempelajari representasi dan hubungan nonlinier melalui beberapa lapisan jaringan saraf sehingga berpotensi digunakan pada permasalahan klasifikasi tersebut. Echevin et al. (2025) menunjukkan bahwa deep neural network dapat digunakan untuk prediksi kemiskinan dengan memanfaatkan kombinasi data survei dan sensus, sementara Yanto et al. (2023) menerapkan pendekatan deep learning untuk prediksi dan klasifikasi status kemiskinan di Indonesia. Temuan tersebut menunjukkan bahwa DNN dapat menjadi pendekatan yang relevan untuk mempelajari pola sosial ekonomi yang tidak sederhana.

Namun, penggunaan DNN pada data sosial ekonomi tingkat rumah tangga tidak dapat hanya didasarkan pada asumsi bahwa model yang lebih kompleks akan menghasilkan prediksi yang lebih baik. Ketika jumlah observasi dan variabel prediktor terbatas, kompleksitas arsitektur DNN justru dapat meningkatkan risiko overfitting, yaitu ketika model terlalu menyesuaikan diri terhadap pola pada data pelatihan tetapi memiliki kemampuan generalisasi yang rendah terhadap data baru. Risiko tersebut menjadi semakin penting pada data mikro tingkat desa karena jumlah sampel umumnya lebih terbatas dibandingkan dataset nasional atau survei berskala besar. Oleh karena itu, pemilihan variabel prediktor harus dilakukan secara selektif dengan mempertimbangkan relevansi terhadap status kelayakan, menghindari variabel yang redundan, serta menyesuaikan kompleksitas arsitektur dengan ukuran dan karakteristik data.

Dengan demikian, penerapan DNN pada penelitian ini tidak diarahkan untuk membangun arsitektur yang semakin kompleks, tetapi untuk memperoleh kompleksitas

model yang proporsional dengan informasi yang tersedia dalam data. Pemilihan variabel sosial ekonomi menjadi bagian penting karena variabel yang terlalu banyak atau kurang relevan dapat meningkatkan dimensi masukan tanpa memberikan informasi prediktif yang sebanding. Sebaliknya, variabel yang relevan dan memiliki hubungan dengan status kelayakan dapat membantu model mempelajari pola yang lebih bermakna. Risiko overfitting selanjutnya perlu dikendalikan melalui pembagian data latih dan uji yang tepat serta evaluasi performa model menggunakan data yang tidak digunakan dalam proses pelatihan.

Berdasarkan penelitian terdahulu, masih terdapat kesenjangan penelitian pada penerapan DNN untuk klasifikasi kelayakan penerima bantuan sosial menggunakan data sosial ekonomi pada tingkat desa dengan jumlah variabel dan observasi yang terbatas. Penelitian sebelumnya banyak dilakukan pada cakupan nasional, provinsi, kabupaten/kota, atau dataset yang relatif besar, sedangkan karakteristik data tingkat desa memiliki skala yang lebih kecil dan konteks sosial ekonomi yang lebih spesifik. Kondisi tersebut menimbulkan kebutuhan untuk menguji apakah DNN dapat diterapkan secara tepat pada data mikro tingkat desa dengan mempertimbangkan pemilihan variabel dan pengendalian kompleksitas model.

Berdasarkan kesenjangan tersebut, penelitian ini dilakukan di Desa Parigi dengan menggunakan karakteristik sosial ekonomi rumah tangga sebagai variabel prediktor dan status kelayakan penerima bantuan sosial sebagai variabel keluaran. Kontribusi utama penelitian ini adalah mengembangkan dan mengevaluasi model DNN yang disesuaikan dengan karakteristik data mikro tingkat desa, dengan memperhatikan pemilihan variabel dan risiko overfitting. Dengan pendekatan tersebut, penelitian tidak hanya mengukur kemampuan DNN dalam melakukan klasifikasi, tetapi juga mengevaluasi kesesuaian kompleksitas model terhadap keterbatasan data yang tersedia.

Kinerja model akan dievaluasi menggunakan accuracy, precision, recall, F1-score, dan AUC untuk mengetahui kemampuan model dalam membedakan rumah tangga yang layak dan tidak layak menerima bantuan. Evaluasi tersebut digunakan untuk menilai kemampuan generalisasi model, bukan sekadar keberhasilan model dalam menyesuaikan data pelatihan. Hasil penelitian diharapkan dapat memberikan kontribusi akademik dalam penerapan deep learning pada penargetan bantuan sosial berbasis data mikro serta kontribusi praktis berupa model yang dapat berfungsi sebagai decision-support system bagi pemerintah desa. Model tersebut tidak dimaksudkan untuk menggantikan proses verifikasi lapangan dan keputusan pemerintah desa, tetapi memberikan dasar analitis yang lebih objektif, konsisten, dan berbasis data dalam proses identifikasi calon penerima bantuan sosial.

METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan memanfaatkan data sekunder yang diperoleh dari Pemerintah Desa Parigi. Data penelitian berupa karakteristik sosial ekonomi rumah tangga yang digunakan untuk mengklasifikasikan kelayakan penerima bantuan sosial. Penelitian dilakukan melalui beberapa tahapan, yaitu pengumpulan data, pemeriksaan dan preprocessing, pemilihan variabel, pembagian data, perancangan model Deep Neural Network (DNN), pelatihan dan validasi model, pengujian, serta evaluasi kinerja model.

Data dan Variabel Penelitian

Dataset awal yang diperoleh dari Pemerintah Desa Parigi kemudian diperiksa

untuk memastikan kelengkapan, konsistensi, dan kesesuaian data dengan kebutuhan penelitian. Setelah proses pemeriksaan dan pembersihan dilakukan, diperoleh 207 data rumah tangga yang digunakan dalam pemodelan.

Variabel prediktor yang digunakan terdiri atas jumlah pendapatan, jumlah tanggungan keluarga, dan kondisi tempat tinggal, sedangkan status kelayakan penerima bantuan sosial digunakan sebagai variabel target. Status kelayakan dikategorikan menjadi dua kelas, yaitu Layak (1) dan Tidak Layak (0).

Pemilihan variabel dilakukan dengan mempertimbangkan keterkaitan langsung variabel tersebut dengan kondisi sosial ekonomi rumah tangga serta ketersediaan data yang konsisten pada seluruh observasi. Ketiga variabel dipertahankan sebagai variabel utama karena merepresentasikan tiga aspek yang berbeda, yaitu kondisi ekonomi melalui pendapatan, beban ekonomi rumah tangga melalui jumlah tanggungan, dan kondisi fisik tempat tinggal sebagai salah satu indikator kesejahteraan. Pembatasan jumlah variabel juga dilakukan untuk menyesuaikan model dengan karakteristik dataset yang relatif kecil dan mengurangi kemungkinan memasukkan variabel yang kurang relevan atau redundan ke dalam model.

Preprocessing Data

Sebelum digunakan dalam proses pemodelan, data melalui tahap *preprocessing* yang meliputi pemeriksaan data tidak lengkap, pemeriksaan data duplikat, pengkodean variabel kategorikal ke dalam bentuk numerik, serta normalisasi variabel numerik.

Variabel jumlah pendapatan dan jumlah tanggungan dinormalisasi ke dalam rentang 0 sampai 1, sedangkan variabel kondisi tempat tinggal dikonversi ke dalam bentuk numerik sesuai dengan kategorinya. Variabel target juga dikodekan menjadi dua kelas, yaitu Layak (1) dan Tidak Layak (0).

Normalisasi dilakukan agar perbedaan skala antarvariabel tidak menyebabkan variabel dengan nilai numerik lebih besar mendominasi proses pembelajaran jaringan saraf. Tahap *preprocessing* juga bertujuan menghasilkan data dengan format yang konsisten sehingga dapat digunakan secara optimal dalam proses pelatihan model. Kualitas dan struktur data merupakan aspek penting dalam penerapan *machine learning* untuk penargetan sosial karena kesalahan atau ketidakkonsistenan data dapat memengaruhi hasil klasifikasi (Wobcke & Mariyah, 2023; Dietrich et al., 2024).

Pembagian Data dan Validasi Model

Dataset sebanyak 207 data dibagi menjadi data pelatihan dan data pengujian dengan proporsi 80:20, sehingga diperoleh 165 data pelatihan dan 42 data pengujian. Data pengujian tidak digunakan dalam proses pembelajaran model dan hanya digunakan untuk mengevaluasi kemampuan model terhadap data yang belum pernah digunakan selama pelatihan.

Mengingat ukuran dataset relatif kecil, evaluasi tidak hanya didasarkan pada satu hasil pembagian data. Untuk mengurangi ketergantungan terhadap satu pembagian dataset dan memperoleh estimasi performa yang lebih stabil, proses pengembangan model perlu disertai dengan k-fold cross-validation pada data pelatihan. Dalam penelitian ini, data pelatihan dapat dibagi ke dalam beberapa *fold* untuk melakukan proses pelatihan dan validasi secara bergantian. Data pengujian tetap disimpan sebagai data yang tidak digunakan selama proses pemilihan dan pelatihan model.

Penggunaan validasi silang penting karena model DNN memiliki kapasitas yang

relatif tinggi dibandingkan jumlah observasi yang tersedia. Tanpa validasi yang memadai, nilai performa dapat terlalu bergantung pada karakteristik satu pembagian data dan berisiko memberikan estimasi kemampuan generalisasi yang kurang stabil. Oleh karena itu, *cross-validation* digunakan sebagai mekanisme tambahan untuk mengevaluasi konsistensi performa model dan membantu mendeteksi indikasi *overfitting*.

Perancangan Model Deep Neural Network


Klasifikasi dilakukan menggunakan model *Deep Neural Network* (DNN). Model menerima tiga variabel masukan, yaitu jumlah pendapatan, jumlah tanggungan keluarga, dan kondisi tempat tinggal.

Arsitektur jaringan dirancang secara sederhana dan disesuaikan dengan ukuran dataset. Model terdiri atas lapisan masukan, lapisan tersembunyi, dan lapisan keluaran. Lapisan tersembunyi menggunakan fungsi aktivasi ReLU (Rectified Linear Unit), sedangkan lapisan keluaran menggunakan Softmax untuk menghasilkan probabilitas pada dua kelas, yaitu Layak dan Tidak Layak.

Penggunaan arsitektur yang relatif sederhana merupakan keputusan metodologis yang disesuaikan dengan ukuran dataset. Dataset penelitian hanya terdiri atas 207 observasi dengan tiga variabel prediktor sehingga penggunaan jaringan yang terlalu dalam dan memiliki terlalu banyak parameter berpotensi meningkatkan kompleksitas model dan risiko *overfitting*. Oleh karena itu, jumlah lapisan dan neuron tidak ditingkatkan secara berlebihan, melainkan disesuaikan dengan karakteristik data dan tujuan penelitian.

Fungsi aktivasi ReLU digunakan pada lapisan tersembunyi karena mampu merepresentasikan hubungan nonlinier antarvariabel dengan komputasi yang relatif sederhana. Sementara itu, Softmax digunakan pada lapisan keluaran karena penelitian merupakan permasalahan klasifikasi dua kelas dan membutuhkan probabilitas prediksi untuk masing-masing kelas.

Dengan karakteristik arsitektur tersebut, istilah *Deep Neural Network* dalam penelitian ini digunakan untuk merujuk pada pendekatan jaringan saraf berbasis *deep learning* yang digunakan untuk mempelajari hubungan nonlinier antara variabel sosial ekonomi dan status kelayakan. Namun, kedalaman jaringan sengaja dibatasi untuk menghindari kompleksitas yang tidak sesuai dengan ukuran dataset. Pendekatan ini menempatkan kesesuaian antara kapasitas model dan ukuran data sebagai pertimbangan utama dalam perancangan arsitektur.



Gambar 1. Ilustrasi Deep Neural Network (DNN)

Pelatihan Model

Model dilatih menggunakan optimizer Adam dengan fungsi *loss categorical crossentropy*. Proses pelatihan dilakukan selama 100 epoch dengan *batch size* 8. Parameter tersebut digunakan untuk memperbarui bobot jaringan berdasarkan kesalahan prediksi selama proses pembelajaran.

Selama proses pelatihan dan validasi, performa model diamati untuk mengetahui apakah peningkatan kemampuan pada data pelatihan diikuti oleh peningkatan performa pada data validasi. Perbedaan performa yang terlalu besar antara data pelatihan dan validasi dapat menjadi indikasi terjadinya *overfitting*. Oleh karena itu, performa validasi menjadi pertimbangan penting dalam menentukan apakah model mampu melakukan generalisasi terhadap data yang tidak digunakan dalam proses pembelajaran.

Evaluasi Model

Setelah proses pelatihan selesai, model diuji menggunakan data pengujian sebanyak 42 observasi. Evaluasi dilakukan menggunakan *confusion matrix* dan beberapa metrik klasifikasi, yaitu accuracy, precision, recall, dan F1-score.

Accuracy digunakan untuk mengukur proporsi keseluruhan prediksi yang diklasifikasikan dengan benar. *Precision* digunakan untuk mengukur ketepatan model ketika memprediksi kelas Layak, sedangkan *recall* digunakan untuk mengukur kemampuan model dalam mengenali rumah tangga yang benar-benar termasuk kelas Layak. *F1-score* digunakan untuk menggambarkan keseimbangan antara *precision* dan *recall*.

Penggunaan beberapa metrik diperlukan karena akurasi saja belum cukup untuk menggambarkan kemampuan model dalam permasalahan penargetan bantuan sosial. Khususnya, *recall* perlu diperhatikan karena berkaitan dengan kemampuan model dalam mengidentifikasi masyarakat yang sebenarnya layak menerima bantuan. Evaluasi menggunakan beberapa metrik dapat memberikan gambaran yang lebih komprehensif mengenai kemampuan klasifikasi model (Ahmad et al., 2023; Hiola et al., 2026).

Pengendalian Risiko Overfitting

Keterbatasan ukuran dataset menjadi salah satu pertimbangan utama dalam pengembangan model DNN pada penelitian ini. Dengan hanya 207 observasi dan tiga variabel prediktor, model dengan arsitektur yang terlalu kompleks berpotensi mempelajari pola spesifik pada data pelatihan yang tidak dapat digeneralisasikan terhadap data baru.

Untuk mengurangi risiko tersebut, penelitian menerapkan beberapa strategi, yaitu membatasi kompleksitas arsitektur jaringan, menggunakan pembagian data pelatihan dan pengujian, serta menerapkan k-fold cross-validation pada data pelatihan. Performa model juga diamati pada data validasi untuk mendeteksi perbedaan yang berlebihan antara performa pelatihan dan validasi.

Dengan strategi tersebut, keberhasilan model tidak hanya ditentukan oleh tingginya akurasi pada data pelatihan, tetapi juga oleh konsistensi performanya pada data yang tidak digunakan selama proses pembelajaran.

Implementasi Model

Model DNN yang telah melalui proses pelatihan dan evaluasi dapat digunakan sebagai komponen prediksi dalam sistem berbasis web. Sistem berfungsi sebagai media pendukung untuk memasukkan karakteristik sosial ekonomi rumah tangga dan memperoleh hasil klasifikasi kelayakan berdasarkan model yang telah dilatih.

Implementasi sistem tidak menjadi bagian utama dari evaluasi kinerja model. Evaluasi penelitian difokuskan pada kemampuan klasifikasi DNN berdasarkan data pengujian, sedangkan sistem berbasis web digunakan sebagai media penerapan hasil model. Keputusan akhir mengenai penerima bantuan tetap berada pada pihak yang berwenang dan perlu mempertimbangkan proses verifikasi serta kebijakan yang berlaku.

HASIL DAN PEMBAHASAN

Hasil Preprocessing dan Pembagian Data

Hasil *preprocessing* menunjukkan bahwa data telah disiapkan dalam format yang sesuai untuk pemodelan. Variabel jumlah pendapatan dan jumlah tanggungan dinormalisasi ke dalam rentang 0 sampai 1, sedangkan kondisi tempat tinggal dikonversi ke bentuk numerik. Status kelayakan digunakan sebagai variabel target dengan dua kategori, yaitu Layak (1) dan Tidak Layak (0). Setelah proses *preprocessing*, diperoleh 207 data yang selanjutnya dibagi menjadi 165 data *training* dan 42 data *testing* dengan proporsi 80:20. Tahap normalisasi dilakukan untuk mengurangi perbedaan skala antarvariabel sehingga proses pembelajaran jaringan saraf dapat berlangsung secara lebih stabil.


Pembagian data menjadi data *training* dan *testing* memungkinkan evaluasi dilakukan terhadap data yang tidak digunakan selama proses pembelajaran. Hal ini penting karena performa model pada data pelatihan tidak dapat secara langsung menggambarkan kemampuan generalisasinya. Dengan jumlah data yang relatif kecil, hasil pengujian perlu ditafsirkan secara hati-hati karena perubahan komposisi data pelatihan dan pengujian dapat memengaruhi nilai metrik yang diperoleh. Oleh karena itu, performa model tidak hanya dinilai berdasarkan akurasi, tetapi juga melalui *precision*, *recall*, *F1-score*, dan analisis kesalahan klasifikasi.

Hasil Pelatihan Model

Proses pelatihan menunjukkan bahwa model mengalami peningkatan kemampuan klasifikasi seiring bertambahnya iterasi, yang ditunjukkan oleh peningkatan *accuracy* dan penurunan *loss*. Pada iterasi ke-29, *accuracy* pelatihan mencapai 98% dengan *loss* sebesar 34%. Pola tersebut menunjukkan bahwa model mampu mempelajari pola hubungan antara variabel pendapatan, jumlah tanggungan, kondisi tempat tinggal, dan status kelayakan.

Untuk memberikan gambaran proses pembelajaran secara lebih ringkas, perkembangan *accuracy* dan *loss* selama pelatihan sebaiknya disajikan dalam bentuk grafik pada **Gambar 2** dan **3**. Grafik tersebut digunakan untuk melihat kecenderungan konvergensi model serta mendeteksi kemungkinan terjadinya *overfitting*. Apabila *accuracy* data pelatihan terus meningkat sementara *accuracy* validasi berhenti meningkat atau menurun, dan *loss* validasi mulai meningkat, kondisi tersebut dapat menjadi indikasi bahwa model mulai terlalu menyesuaikan diri terhadap data pelatihan.

Karena dataset penelitian hanya berjumlah 207 observasi, pencapaian *accuracy* pelatihan sebesar 98% tidak dapat dijadikan dasar tunggal untuk menyatakan bahwa model memiliki kemampuan generalisasi yang tinggi. Evaluasi terhadap data yang tidak digunakan selama pelatihan menjadi lebih penting untuk menilai kemampuan model dalam menghadapi data baru.



Gambar 2. Grafik Loss Selama Training Model



Gambar 3. Grafik Accuracy Selama Training Model

Hasil Confusion Matrix dan Analisis Kesalahan Prediksi

Berdasarkan *confusion matrix*, dari 42 data *testing* terdapat 23 data Layak yang berhasil diprediksi sebagai Layak (*True Positive*) dan 17 data Tidak Layak yang berhasil diprediksi sebagai Tidak Layak (*True Negative*). Selain itu, terdapat 2 data Tidak Layak yang diprediksi sebagai Layak (*False Positive*) dan tidak terdapat data Layak yang diprediksi sebagai Tidak Layak (*False Negative*). Dengan demikian, sebanyak 40 dari 42 data berhasil diklasifikasikan dengan benar.

Komposisi tersebut menghasilkan *recall* sebesar 100% karena seluruh 23 rumah tangga yang termasuk kategori Layak pada data pengujian berhasil dikenali oleh model. Dari perspektif penargetan bantuan sosial, hasil tersebut memiliki implikasi penting karena tidak ditemukan *False Negative*. Artinya, pada sampel pengujian ini tidak terdapat rumah tangga yang berstatus Layak tetapi diprediksi sebagai Tidak Layak. Kondisi tersebut menunjukkan bahwa model memiliki sensitivitas yang tinggi dalam mengenali kelompok yang membutuhkan bantuan.

Namun, *recall* sebesar 100% tidak dapat langsung diartikan bahwa model telah sempurna. Nilai tersebut diperoleh dari 23 data positif pada *testing set* yang berukuran hanya 42 observasi. Oleh karena itu, satu atau beberapa perubahan pada komposisi data dapat berpotensi mengubah nilai *recall* secara signifikan. Hasil tersebut perlu dipertimbangkan bersama ukuran dataset dan validasi model untuk memastikan bahwa performa yang tinggi bukan akibat karakteristik khusus dari pembagian data.

Hal yang lebih penting dalam konteks kebijakan adalah adanya 2 False Positive (FP). Kedua data tersebut merupakan rumah tangga yang sebenarnya termasuk kategori Tidak Layak tetapi diprediksi sebagai Layak. Kesalahan ini berkaitan dengan inclusion error, yaitu kondisi ketika bantuan berpotensi diberikan kepada pihak yang sebenarnya tidak termasuk sasaran. Meskipun jumlahnya hanya 2 dari 42 data pengujian, dampaknya tidak dapat dinilai hanya berdasarkan persentase kesalahan karena bantuan sosial merupakan sumber daya publik yang jumlahnya terbatas.

False Positive dapat menyebabkan alokasi bantuan kepada rumah tangga yang sebenarnya tidak memenuhi kriteria sehingga berpotensi mengurangi kesempatan rumah tangga lain yang lebih membutuhkan untuk memperoleh bantuan. Dengan demikian, tingginya *recall* perlu dibaca bersama dengan nilai *precision* sebesar 92%. Nilai tersebut menunjukkan bahwa sebagian besar rumah tangga yang diprediksi Layak memang termasuk kategori Layak, tetapi masih terdapat sejumlah prediksi positif yang salah.

Dari sisi kebijakan, hasil ini menunjukkan adanya trade-off antara meminimalkan exclusion error dan mengendalikan inclusion error. Model pada penelitian ini cenderung lebih sensitif dalam menemukan rumah tangga Layak, tetapi masih menghasilkan sejumlah prediksi Layak yang sebenarnya Tidak Layak. Apabila prioritas utama adalah memastikan masyarakat yang layak tidak terlewatkan, karakteristik tersebut dapat dianggap menguntungkan. Sebaliknya, apabila keterbatasan anggaran menjadi pertimbangan utama, *False Positive* perlu mendapat perhatian karena dapat meningkatkan risiko penyaluran bantuan kepada penerima yang tidak tepat.

Oleh karena itu, hasil prediksi DNN tidak sebaiknya digunakan sebagai keputusan akhir penerima bantuan. Model lebih tepat ditempatkan sebagai alat bantu penyaringan awal yang kemudian dilanjutkan dengan verifikasi administratif dan lapangan oleh pihak yang berwenang. Pendekatan tersebut dapat mempertahankan manfaat model dalam mengidentifikasi kelompok yang berpotensi layak sekaligus mengurangi dampak sosial dari kesalahan klasifikasi.

Evaluasi Kinerja Model

Berdasarkan 42 data *testing*, model menghasilkan *accuracy* sebesar 95,24%, *precision* sebesar 92,00%, *recall* sebesar 100,00%, dan *F1-score* sebesar 95,83%.

Accuracy sebesar 95,24% menunjukkan bahwa 40 dari 42 data pengujian diklasifikasikan dengan benar. Namun, dalam konteks penargetan bantuan sosial, *accuracy* bukan satu-satunya ukuran keberhasilan. *Recall* sebesar 100% menunjukkan bahwa seluruh data aktual kelas Layak berhasil dikenali, sedangkan *precision* sebesar 92% menunjukkan bahwa masih terdapat dua prediksi Layak yang tidak sesuai dengan kondisi aktual. Dengan demikian, hasil evaluasi menunjukkan bahwa model memiliki kecenderungan kuat untuk menghindari *False Negative*, tetapi masih memiliki risiko *False Positive*.

Nilai *F1-score* sebesar 95,83% menunjukkan bahwa model memiliki keseimbangan yang baik antara *precision* dan *recall* pada data pengujian. Meskipun demikian, nilai tersebut harus dipahami dalam konteks ukuran dataset yang relatif kecil. Oleh sebab itu, hasil penelitian ini lebih tepat diinterpretasikan sebagai bukti bahwa DNN berpotensi digunakan untuk klasifikasi kelayakan bantuan sosial pada data Desa Parigi, bukan sebagai bukti bahwa model akan memiliki performa yang sama pada populasi atau wilayah yang lebih luas.

Perbandingan dengan Model Baseline

Untuk memastikan bahwa kinerja DNN tidak hanya disebabkan oleh karakteristik tertentu dari dataset atau pembagian data, model perlu dibandingkan dengan algoritma baseline. Dua model yang relevan adalah Logistic Regression sebagai pendekatan klasifikasi linear dan Random Forest sebagai pendekatan ensemble tree-based.

Perbandingan dilakukan menggunakan pembagian data dan prosedur evaluasi yang sama sehingga hasil antar-model dapat dibandingkan secara adil. Metrik yang digunakan meliputi *accuracy*, *precision*, *recall*, *F1-score*, dan AUC.

Perbandingan tersebut penting karena DNN memiliki kapasitas model yang lebih tinggi dibandingkan model linear sederhana. Jika DNN hanya menghasilkan performa yang setara atau lebih rendah daripada *baseline*, maka kompleksitas tambahan DNN perlu dipertimbangkan kembali, khususnya karena dataset penelitian

relatif kecil. Sebaliknya, apabila DNN menunjukkan performa yang lebih baik secara konsisten pada data validasi dan pengujian, hasil tersebut dapat menjadi bukti yang lebih kuat mengenai manfaat penggunaan DNN pada karakteristik data penelitian.

Dengan demikian, pemilihan DNN tidak hanya didasarkan pada nilai akurasi yang tinggi, tetapi pada kemampuannya memberikan performa yang konsisten dan kompetitif dibandingkan metode klasifikasi yang lebih sederhana.

PEMBAHASAN

Hasil penelitian menunjukkan bahwa DNN mampu menghasilkan performa klasifikasi yang tinggi pada data pengujian Desa Parigi. Akan tetapi, performa tersebut harus dipahami bersama beberapa keterbatasan. Dataset hanya terdiri atas 207 observasi dan menggunakan tiga variabel prediktor, yaitu pendapatan, jumlah tanggungan, dan kondisi tempat tinggal. Kondisi tersebut membatasi kompleksitas informasi yang dapat dipelajari model sekaligus meningkatkan pentingnya pengendalian *overfitting* pada arsitektur jaringan.

Nilai *recall* sebesar 100% perlu menjadi perhatian khusus karena diperoleh dari dataset pengujian yang relatif kecil. Tidak ditemukannya *False Negative* merupakan hasil yang positif dari sisi perlindungan terhadap risiko *exclusion error*, tetapi belum cukup untuk menyimpulkan bahwa model akan selalu mampu mengidentifikasi seluruh rumah tangga yang layak pada data baru. Validasi silang dan pengujian pada dataset yang lebih besar diperlukan untuk memperoleh estimasi generalisasi yang lebih kuat.

Sementara itu, dua *False Positive* menunjukkan bahwa model masih memiliki kemungkinan menghasilkan *inclusion error*. Kesalahan tersebut memiliki konsekuensi sosial karena dapat menyebabkan sumber daya bantuan dialokasikan kepada rumah tangga yang tidak termasuk sasaran. Oleh karena itu, evaluasi model untuk penargetan bantuan sosial seharusnya tidak hanya berorientasi pada pencapaian akurasi, tetapi juga mempertimbangkan jenis kesalahan dan konsekuensi dari setiap kesalahan terhadap kelompok penerima.

Hasil penelitian ini juga menunjukkan bahwa penggunaan DNN pada data mikro perlu dilakukan secara proporsional. Model yang lebih kompleks tidak selalu menghasilkan model yang lebih baik apabila informasi yang tersedia terbatas. Penggunaan variabel yang relevan, arsitektur yang sederhana, validasi yang memadai, serta perbandingan dengan model *baseline* diperlukan agar peningkatan kompleksitas model benar-benar memberikan manfaat prediktif.

Implementasi Model

Model DNN kemudian diintegrasikan ke dalam sistem berbasis web sebagai media penerapan hasil klasifikasi. Sistem digunakan untuk memasukkan data sosial ekonomi dan menampilkan hasil prediksi kelayakan.

Pembahasan mengenai antarmuka dan fungsi sistem tidak menjadi fokus utama penelitian ini. Pengujian fungsional sistem dapat dilaporkan secara singkat sebagai informasi pendukung, sedangkan pembahasan utama tetap diarahkan pada kinerja model, kemampuan generalisasi, dan implikasi kesalahan klasifikasi terhadap penargetan bantuan sosial.

Ringkasan Temuan

Secara keseluruhan, model DNN menghasilkan *accuracy* sebesar 95,24%,

precision 92,00%, *recall* 100,00%, dan *F1-score* 95,83% pada 42 data pengujian. Hasil *confusion matrix* menunjukkan 23 *True Positive*, 17 *True Negative*, 2 *False Positive*, dan 0 *False Negative*. Dengan demikian, kekuatan utama model pada data pengujian terletak pada kemampuannya mengenali seluruh data aktual kelas Layak, sedangkan kelemahan yang perlu diperhatikan adalah masih adanya *False Positive* yang berpotensi menimbulkan *inclusion error*.

Oleh karena itu, keberhasilan model tidak hanya ditunjukkan oleh tingginya nilai *accuracy*, tetapi juga perlu dilihat dari konsekuensi jenis kesalahan yang dihasilkan. Dalam konteks bantuan sosial, model yang baik adalah model yang memiliki kemampuan diskriminasi dan generalisasi yang memadai serta mampu memberikan keseimbangan antara risiko *exclusion error* dan *inclusion error*. DNN dalam penelitian ini menunjukkan potensi sebagai alat bantu analisis penargetan sosial pada tingkat desa, tetapi penerapannya tetap memerlukan validasi lebih lanjut, perbandingan dengan model *baseline*, serta verifikasi terhadap kondisi nyata masyarakat.

KESIMPULAN

Penelitian ini menunjukkan bahwa *Deep Neural Network* (DNN) dapat diterapkan untuk mengklasifikasikan kelayakan penerima bantuan sosial berdasarkan karakteristik sosial ekonomi rumah tangga. Dengan memanfaatkan variabel jumlah pendapatan, jumlah tanggungan, dan kondisi tempat tinggal, model mampu mengenali pola klasifikasi pada data tingkat desa dan menghasilkan kinerja yang baik pada data pengujian. Hasil tersebut menunjukkan bahwa pendekatan berbasis pembelajaran mesin memiliki potensi untuk mendukung proses identifikasi penerima bantuan sosial secara lebih terstruktur dan berbasis data.

Secara teknis, kontribusi penelitian ini terletak pada penerapan DNN untuk mengolah hubungan antarvariabel sosial ekonomi dalam klasifikasi kelayakan bantuan sosial pada skala data mikro. Model mampu mengenali seluruh data yang termasuk kategori Layak pada data pengujian, tetapi masih menghasilkan beberapa *False Positive*. Kondisi tersebut menunjukkan bahwa model masih memiliki potensi menghasilkan *inclusion error*, sehingga hasil klasifikasi belum dapat dipandang sebagai keputusan akhir. Selain itu, keterbatasan jumlah data dan penggunaan tiga variabel prediktor menyebabkan kemampuan generalisasi model masih perlu diuji lebih lanjut pada dataset yang lebih besar dan lebih beragam.

Secara manajerial, hasil penelitian dapat menjadi dasar bagi pemangku kepentingan di tingkat desa dalam menggunakan informasi berbasis data sebagai salah satu bahan pertimbangan untuk proses identifikasi dan penentuan calon penerima bantuan sosial. Hasil prediksi model sebaiknya digunakan sebagai instrumen pendukung dalam pemetaan dan penyaringan awal, kemudian dikombinasikan dengan verifikasi kondisi aktual masyarakat. Pendekatan tersebut penting agar keputusan penyaluran bantuan tidak hanya bergantung pada hasil prediksi algoritma, tetapi tetap mempertimbangkan validitas data dan kondisi sosial ekonomi masyarakat di lapangan.

SARAN

Penelitian selanjutnya disarankan melakukan penanganan terhadap kemungkinan *class imbalance* sebelum proses pelatihan, misalnya melalui penggunaan *class weight*, *oversampling* seperti SMOTE, atau strategi resampling lain yang sesuai

dengan karakteristik dataset. Evaluasi juga sebaiknya tidak hanya mengandalkan *accuracy*, tetapi mempertimbangkan *precision*, *recall*, *F1-score*, AUC-ROC, dan analisis *confusion matrix* untuk memastikan bahwa model tidak hanya unggul pada kelas mayoritas.

Selain itu, jumlah dan keragaman fitur perlu diperluas dengan memasukkan indikator sosial ekonomi yang lebih multidimensi, seperti tingkat pendidikan, status pekerjaan, kepemilikan aset, jumlah anggota keluarga, kondisi sanitasi, akses terhadap fasilitas dasar, serta karakteristik tempat tinggal lainnya apabila data tersedia dan relevan. Penambahan fitur perlu disertai proses seleksi variabel agar fitur yang tidak informatif atau redundan tidak meningkatkan kompleksitas model dan risiko *overfitting*.

Dari sisi arsitektur, penelitian mendatang dapat menguji arsitektur DNN yang lebih sesuai dengan karakteristik dan ukuran data, misalnya dengan penambahan *hidden layer* secara bertahap, penggunaan *dropout* dan *L2 regularization* untuk mengendalikan *overfitting*, serta penerapan *early stopping* berdasarkan kinerja validasi. Pengujian juga dapat diperluas dengan membandingkan DNN dengan model *ensemble* dan algoritma klasifikasi lainnya, seperti Random Forest, XGBoost, atau Support Vector Machine. Penggunaan *stratified k-fold cross-validation* juga disarankan untuk memperoleh estimasi kinerja yang lebih stabil dan mengurangi ketergantungan terhadap satu pembagian data *training* dan *testing*.

Pernyataan Penggunaan Kecerdasan Buatan

Kecerdasan buatan (AI) digunakan dalam penyusunan naskah ini. Penulis menggunakan alat-alat AI semata-mata untuk membantu penyempurnaan bahasa, pemeriksaan tata bahasa, dan penyuntingan guna memastikan kejelasan dan keterbacaan naskah. Penulis tetap bertanggung jawab penuh atas keakuratan, orisinalitas, integritas, dan isi akademis naskah ini. Seluruh isi yang dihasilkan dengan bantuan AI telah ditinjau dan diverifikasi oleh penulis sebelum naskah ini diajukan.

Konflik Kepentingan

Penulis menyatakan tidak ada konflik kepentingan

Kontribusi Penulis

Konseptualisasi, SR dan FIR; pengumpulan data, SR; validasi data, SR; analisis formal, SR dan MAH; penulisan—penyusunan draf awal, SR dan RYB; penulisan—peninjauan dan penyuntingan, SR dan TW; visualisasi, SR dan D. Semua penulis telah membaca dan menyetujui versi akhir naskah ini.

Ucapan Terima Kasih

Ucapan terima kasih yang tulus disampaikan kepada COCONUT Computer Club dan Universitas Muhammadiyah Makassar atas dukungan fasilitas dan infrastruktur yang menunjang proses pengembangan serta pengujian sistem, khususnya dalam pemanfaatan sumber daya komputasi berbasis GPU. Terima kasih juga disampaikan kepada rekan-rekan yang telah memberikan dukungan, bantuan, dan masukan selama proses penelitian dan pengembangan sistem. Apresiasi yang sebesar-besarnya turut disampaikan kepada keluarga dan rekan kerja atas dukungan moral, motivasi, serta semangat yang diberikan sehingga penelitian dan penyusunan karya ini dapat diselesaikan dengan baik.

REFERENSI

- Agyemang, F. S. K., Memon, R., Wolf, L. J., & Fox, S. (2023). High-resolution rural poverty mapping in Pakistan with ensemble deep learning. *PLOS ONE*, 18(4), e0283938. <https://doi.org/10.1371/journal.pone.0283938>
- Ahmad, M., Prabowo, H., Hendric Spits Warnars, H. L., & Gaol, F. L. (2023). A machine learning approach for model selection of social aid beneficiaries. *Journal of System and Management Sciences*, 13(6), 230–243. <https://doi.org/10.33168/JSMS.2023.0614>
- Aiken, E., Bellue, S., Karlan, D., Udry, C., & Blumenstock, J. E. (2022). Machine learning and phone data can improve targeting of humanitarian aid. *Nature*, 603(7903), 864–870. <https://doi.org/10.1038/s41586-022-04484-9>
- Aprilia, R., et al. (2024). Neural network for poverty classification in Batang Regency. *Journal of Applied Intelligent System*.
- Beuermann, D. W., Hoffmann, B., Stampini, M., Vargas, D. L., & Vera-Cossio, D. A. (2025). Shooting a moving target: Evaluating targeting tools for social programs when income fluctuates. *Journal of Development Economics*, 172, 103395. <https://doi.org/10.1016/j.jdeveco.2024.103395>
- Dietrich, S., Malerba, D., & Gassmann, F. (2024). Predicting social assistance beneficiaries: On the social welfare damage of data biases. *Data & Policy*, 6, e3. <https://doi.org/10.1017/dap.2023.38>
- Echevin, D., Fotso, G., Bouroubi, Y., Coulombe, H., & Li, Q. (2025). Combining survey and census data for improved poverty prediction using semi-supervised deep learning. *Journal of Development Economics*, 172, 103385. <https://doi.org/10.1016/j.jdeveco.2024.103385>
- Follett, L., & Henderson, H. (2023). A hybrid approach to targeting social assistance. *Journal of Development Economics*, 160, 103002. <https://doi.org/10.1016/j.jdeveco.2022.103002>
- Gazeaud, J. (2020). Proxy means testing vulnerability to measurement errors? *The Journal of Development Studies*, 56(11), 2113–2133. <https://doi.org/10.1080/00220388.2020.1715942>
- Grosh, M., Leite, P., Wai-Poi, M., & Tesliuc, E. (2022). A synopsis of “Revisiting targeting in social assistance: A new look at old dilemmas.” *Global Social Policy*, 22(3), 434–448. <https://doi.org/10.1177/14680181221121442>
- Hall, O., Ohlsson, M., & Rögnvaldsson, T. S. (2022). A review of explainable AI in the satellite data, deep machine learning, and human poverty domain. *Patterns*, 3(10), 100600. <https://doi.org/10.1016/j.patter.2022.100600>
- Hiola, Y. P., Zulhijrah, Putra, I. G. N. S., Limba, S. Z., Sartono, B., Firdawanti, A. R., Susetyo, B., & Dito, G. A. (2026). Evaluation of tree-based models for predicting social assistance recipient status based on National Socio-Economic Survey (SUSENAS) 2024. *Journal of Mathematics, Computations and Statistics*, 9(1), 15–38. <https://doi.org/10.35580/xyyv0f37>
- Khalik, M. F. M., & Arifin, F. (2023). Classification of the poverty depth index in South Sulawesi Province based on Decision Tree, K-Nearest Neighbor, Naive Bayes, Neural Network, and Random Forest. *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, 9(2). <https://doi.org/10.26418/jp.v9i2.67492>
- Liu, H., Liu, Y., Qin, Z., Zhang, R., Zhang, Z., & Mu, L. (2021). A novel DBSCAN clustering algorithm via edge computing-based deep neural network model for targeted poverty alleviation big data. *Wireless Communications and Mobile Computing*,

- 2021, 5536579. <https://doi.org/10.1155/2021/5536579>
- Mariyah, S., & Wobcke, W. (2025). Selective guided domain adaptation for improving the proxy means test for poverty targeting. *International Journal of Data Science and Analytics*, 20, 5999–6017. <https://doi.org/10.1007/s41060-025-00802-2>
- Martinez, R. G., & Cooray, M. (2025). *Enhancing poverty targeting with spatial machine learning: An application to Indonesia*. arXiv. <https://doi.org/10.48550/arXiv.2503.04300>
- Nazmi, A. M., Prajoko, & Pambudi, A. (2024). Classification analysis of the eligibility of recipients of non-cash food assistance and Family Hope Programs in the City of Sukabumi using the Naïve Bayes Classifier algorithm. *Journal of Artificial Intelligence and Engineering Applications*, 3(2), 546–550. <https://doi.org/10.59934/jaiea.v3i2.420>
- Smythe, I. S., & Blumenstock, J. E. (2022). Geographic microtargeting of social assistance with high-resolution poverty maps. *Proceedings of the National Academy of Sciences*, 119. <https://doi.org/10.1073/pnas.2120025119>
- Taufiq, N., & Suyasa, I. M. G. (2023). Is the wealth index better than the proxy means test in poverty targeting? A study in Brebes and East Jakarta. *Proceedings of the International Conference on Data Science and Official Statistics*. <https://doi.org/10.34123/icdsos.v2023i1.302>
- Usmanova, A., Aziz, A., Rakhmonov, D., & Osamy, W. (2022). Utilities of artificial intelligence in poverty prediction: A review. *Sustainability*, 14(21), 14238. <https://doi.org/10.3390/su142114238>
- Wobcke, W., & Mariyah, S. (2023). Machine learning and data augmentation in the proxy means test for poverty targeting. *Statistical Journal of the IAOS*, 39(4), 961–977. <https://doi.org/10.3233/SJI-230033>
- Yanto, M., Wiyandra, Y., & Defit, S. (2023). Deep learning approach analysis model prediction and classification poverty status. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 12(1), 459–468. <https://doi.org/10.11591/ijai.v12.i1.pp459-468>