

**PREDIKSI PREDIKAT KELULUSAN MAHASISWA MENGGUNAKAN DEEP
NEURAL NETWORK DENGAN HESSIAN-FREE OPTIMIZATION**

TESIS

Oleh:

**ANDY IRAWAN
(NIM. 240605210032)**



**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN JUDUL

**PREDIKSI PREDIKAT KELULUSAN MAHASISWA MENGGUNAKAN
DEEP NEURAL NETWORK DENGAN HESSIAN-FREE OPTIMIZATION**

TESIS

Oleh:

**ANDY IRAWAN
(NIM. 240605210032)**



**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

LEMBAR PENGAJUAN

**PREDIKSI PREDIKAT KELULUSAN MAHASISWA MENGGUNAKAN
DEEP NEURAL NETWORK DENGAN HESSIAN-FREE OPTIMIZATION**

TESIS

Diajukan kepada:

**Universitas Islam Negeri Maulana Malik Ibrahim Malang Untuk
memenuhi Salah Satu Persyaratan dalam Memperoleh Gelar
Magister Komputer (M.Kom)**

Oleh:

**ANDY IRAWAN
(NIM. 240605210032)**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

LEMBAR PERSETUJUAN

PREDIKSI PREDIKAT KELULUSAN MAHASISWA MENGGUNAKAN DEEP NEURAL NETWORK DENGAN HESSIAN-FREE OPTIMIZATION

TESIS

Oleh:

ANDY IRAWAN
NIM. 240605210032

Telah diperiksa dan disetujui untuk diuji:
Tanggal: 11 Mei 2026

Pembimbing I,



Dr. Zainal Abidin, S.Kom., M. Kom
NIP. 197606132005011004

Pembimbing II,



Dr. Mohammad Jamhuri, S.Si., M.Si
NIP. 198105022005011004

Mengetahui dan Mengesahkan
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Prof. Dr. H. Muhammad Faisal, S. Kom., M.T
NIP. 19740510 200501 1 007

LEMBAR PENGESAHAN

PREDIKSI PREDIKAT KELULUSAN MAHASISWA MENGGUNAKAN DEEP NEURAL NETWORK DENGAN HESSIAN-FREE OPTIMIZATION

TESIS

Oleh:

ANDY IRAWAN

NIM. 240605210032

Telah Dipertahankan di Depan Dewan Penguji Tesis
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan Untuk Memperoleh Gelar
Magister Komputer (M.Kom)

Tanggal: 25 Mei 2026

Susunan Dewan Penguji

Penguji I : Dr. Ririen Kusumawati, M.Kom
NIP. 197203092005012002

Penguji II : Dr. Cahyo Crysdiyan, M.CS
NIP. 197404242009011008


Pembimbing I : Dr. Zainal Abidin, S.Kom., M. Kom
NIP. 197606132005011004

Pembimbing II : Dr. Mohammad Jamhuri, S.Si., M.Si
NIP. 198105022005011004

Tanda Tangan

()

()

()

()

Mengetahui dan Mengesahkan
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang


Prof. Dr. H. Muhammad Faisal, S. Kom., M.T
NIP. 19740310 200501 1 007

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan dibawah ini:

Nama : Andy Irawan
NIM : 240605210032
Program Studi : Magister Informatika
Fakultas : Sains dan Teknologi

Menyatakan dengan sebenarnya bahwa Tesis yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambilalihan data, tulisan atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka. Apabila dikemudian hari terbukti atau dapat dibuktikan Tesis ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 11 Mei 2026
Membuat Pernyataan,



Andy Irawan
NIM. 240605210032

MOTTO

” JALANI HIDUP SEDERHANA DAN MENERIMA APA ADANYA ”

HALAMAN PERSEMBAHAN

Dengan penuh rasa syukur kepada Allah SWT atas segala rahmat, karunia, dan pertolongan-Nya, karya sederhana ini saya persembahkan kepada:

Bapak dan Ibu tercinta, atas segala kasih sayang, doa, didikan, serta nilai-nilai kehidupan yang telah ditanamkan sejak kecil. Terima kasih atas pengorbanan dan keikhlasan yang tidak pernah dapat terbalaskan sepenuhnya.

Istriku tercinta, Elita Prameilia, terima kasih atas doa yang tak pernah putus, kesabaran yang tak terbatas, dukungan yang tulus, serta pengorbanan yang luar biasa selama proses studi ini. Engkau adalah sumber kekuatan dan inspirasi dalam setiap langkah perjuangan ini.

Anak-anakku tersayang, Indy, Rere, Kenzie, dan Chio, yang menjadi penyemangat terbesar dalam hidup saya. Semoga karya ini menjadi teladan bahwa kerja keras, ketekunan, dan doa akan selalu membuahkan hasil.

Bapak Zainal dan Bapak Jamhuri selaku dosen pembimbing, atas bimbingan, arahan, kesabaran, dan ilmu yang sangat berharga selama proses penyusunan tesis ini. Setiap masukan dan kritik yang diberikan menjadi bekal berharga dalam perjalanan akademik saya.

Teman-teman seperjuangan satu angkatan, terima kasih atas kebersamaan, diskusi, dukungan, dan semangat yang saling menguatkan selama masa studi ini. Perjalanan ini menjadi lebih bermakna karena kita melaluinya bersama.

Serta kepada semua pihak yang tidak dapat saya sebutkan satu per satu, yang telah memberikan dukungan, doa, dan kontribusi dalam berbagai bentuk hingga tesis ini dapat terselesaikan.

Semoga karya ini menjadi bagian kecil dari perjalanan panjang pengabdian dan kontribusi bagi ilmu pengetahuan dan dunia pendidikan.

KATA PENGANTAR

Assalamu'alaikum Wr. Wb.

Puji dan syukur penulis panjatkan ke hadirat Allah SWT atas segala rahmat, karunia, dan hidayah-Nya sehingga tesis ini dapat diselesaikan dengan baik. Tesis yang berjudul “Prediksi Predikat Kelulusan Mahasiswa Menggunakan *Deep Neural Network* dengan *Hessian-Free Optimization*” ini disusun sebagai salah satu syarat untuk memperoleh gelar akademik pada program studi yang penulis tempuh.

Penelitian ini dilatarbelakangi oleh pentingnya pemanfaatan teknologi kecerdasan buatan dalam mendukung pengambilan keputusan di lingkungan pendidikan tinggi, khususnya dalam memprediksi predikat kelulusan mahasiswa secara lebih akurat dan berbasis data. Melalui pendekatan Deep Neural Network (DNN) dengan perbandingan beberapa metode optimisasi, penelitian ini diharapkan dapat memberikan kontribusi akademik maupun praktis dalam pengembangan sistem prediksi di perguruan tinggi.

Penyusunan tesis ini tidak terlepas dari dukungan, bimbingan, dan bantuan dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Dr. Zainal Abidin, S.Kom., M. Kom dan Dr. Mohammad Jamhuri, S.Si., M.Si selaku dosen pembimbing yang telah memberikan arahan, bimbingan, masukan, serta motivasi dengan penuh kesabaran selama proses penyusunan tesis ini.
2. Bapak dan Ibu dosen di lingkungan program studi yang telah memberikan ilmu dan wawasan selama masa perkuliahan.
3. Orang tua tercinta, Bapak dan Ibu, atas doa, kasih sayang, serta dukungan moral yang tiada henti.

4. Istri tercinta, Elita Prameilia, serta anak-anak tersayang Indy, Rere, Kenzie, dan Chio, yang senantiasa memberikan doa, semangat, dan pengertian selama penulis menyelesaikan studi ini.
5. Teman-teman seperjuangan satu angkatan yang telah memberikan dukungan, kebersamaan, dan semangat dalam menyelesaikan studi.
6. Semua pihak yang tidak dapat disebutkan satu per satu yang telah membantu dalam penyelesaian tesis ini.

Penulis menyadari bahwa tesis ini masih memiliki keterbatasan dan kekurangan. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan demi penyempurnaan penelitian di masa mendatang. Semoga tesis ini dapat memberikan manfaat bagi pengembangan ilmu pengetahuan, khususnya dalam bidang data mining dan kecerdasan buatan di sektor pendidikan.

Akhir kata, semoga segala upaya dan kontribusi dalam penelitian ini menjadi amal kebaikan dan memberikan manfaat yang luas.

Wassalamu'alaikum Wr. Wb.

Malang, 11 Mei 2026
Penulis

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PENGAJUAN.....	ii
LEMBAR PERSETUJUAN.....	iii
LEMBAR PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN.....	v
MOTTO.....	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xiv
DAFTAR TABEL	xv
Abstrak	xvi
Abstract	xvii
ملخص.....	xviii
BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Pernyataan Masalah.....	5
1.3. Tujuan Penelitian.....	5
1.4. Manfaat Penelitian.....	6
1.5. Batasan Masalah.....	6
BAB II TINJAUAN PUSTAKA	8
2.1. Predikat Kelulusan Mahasiswa	8
2.1.1. Pendidikan Tinggi dan Predikat Kelulusan	8
2.1.2. Faktor-Faktor yang Mempengaruhi Capaian Akademik.....	9
a. Faktor Akademik.....	10
b. Faktor Non-Akademik	10
2.1.3. Educational Data Mining (EDM)	11
a. Definisi EDM	11

b. Metode-metode yang umum digunakan dalam EDM.....	12
2.1.4. Deep Neural Network	13
a. Struktur Dasar DNN	13
b. Algoritma Optimisasi dalam Deep Neural Network	15
2.2. Penelitian Terkait	20
2.3. Kerangka Teori.....	22
BAB III METODOLOGI PENELITIAN.....	29
3.1. Desain Penelitian.....	29
3.2. Kerangka Konsep	30
3.3. Kerangka Penelitian	32
3.4. Sumber Data dan Variabel Penelitian.....	36
3.5. Tahapan Pra-pemrosesan Data.....	40
3.6. Desain Arsitektur Model.....	44
3.7. Algoritma Optimisasi	48
3.8. Skenario Eksperimen.....	56
3.9. Metrik Evaluasi	58
BAB IV HASIL DAN ANALISIS	60
4.1. Deskripsi Data.....	60
4.1.1. Karakteristik Umum Dataset	60
4.1.2. Relevansi Data terhadap Tujuan Penelitian.....	62
4.2. Prapemrosesan Data	62
4.2.1. Pembersihan dan Imputasi Data	63
4.2.2. Pembagian Dataset (Data Splitting).....	66
4.2.3. Transformasi Variabel (Encoding dan Scaling)	67
4.2.4. Transformasi dan Penyiapan Label Target.....	68
4.2.5. Hasil Akhir Pra-Pemrosesan Data	69
4.3. Analisis Kontribusi Variabel (Pearson Correlation)	70
4.3.1. Penerapan <i>Pearson Correlation</i> pada Dataset.....	70
4.3.2. Hasil Analisis Korelasi Variabel Akademik.....	71
4.3.3. Hasil Analisis Korelasi Variabel Non-Akademik.....	72

4.3.4. Interpretasi Hasil Korelasi.....	73
4.4. Hasil Evaluasi Model Deep Neural Network.....	75
4.4.1. Analisis Kurva Loss dan Akurasi	75
4.4.2. Evaluasi Kinerja Model DNN	78
a. Evaluasi Kinerja Model DNN menggunakan SGD dengan Momentum.....	79
b. Evaluasi Kinerja Model DNN Menggunakan RMSProp.....	82
c. Evaluasi Kinerja Model DNN Menggunakan Adam.....	84
d. Evaluasi Kinerja Model DNN Menggunakan Hessian-Free Optimization (HFO)	85
4.4.3. Ringkasan Komparatif Kinerja Optimizer	88
4.5. Studi Ablasi Fitur	90
4.5.1. Hasil evaluasi Model Akademik.....	90
4.5.2. Hasil Studi Ablasi Fitur.....	94
BAB V PEMBAHASAN	96
5.1. Pembahasan Hasil Evaluasi Model Prediksi Predikat Kelulusan	96
5.1.1. Keunggulan HFO dalam Akurasi Global dan Konvergensi.....	96
5.1.2. Kelemahan HFO pada Kelas Minoritas (Class Imbalance).....	97
5.2. Pembahasan Perbandingan Kinerja Optimizer	98
5.2.1. First-Order Optimizers sebagai Baseline (SGDM, RMSProp, Adam)	98
5.2.2. HFO sebagai Second-Order Optimization (Metode yang Diusulkan).....	99
5.3. Pembahasan Studi Ablasi Fitur.....	100
5.3.1. Variabel Akademik sebagai Prediktor Dominan	100
5.3.2. Kontribusi Komplementer Variabel Non-Akademik.....	100
5.4. Implikasi Penelitian.....	101
5.5. Integrasi Sains dan Islam dalam Pengembangan Model Prediksi.....	101
5.5.1. Dasar Teologis Pengembangan Ilmu	101
5.5.2. Etika Data dan Keadilan Model (Fairness)	102
5.5.3. Prediksi sebagai Alat Bantu, Bukan Pelabelan Final.....	103

5.6. Keterbatasan Penelitian	104
BAB VI KESIMPULAN DAN SARAN	106
6.1. Kesimpulan	106
6.2. Saran	108
DAFTAR PUSTAKA.....	110
LAMPIRAN.....	113

DAFTAR GAMBAR

Gambar 2. 1 Kerangka Teori	23
Gambar 3. 1 Kerangka Konsep.....	30
Gambar 3. 2 Kerangka Penelitian	33
Gambar 3. 3 Desain Arsitektur Model MLP feedforward.....	44
Gambar 4. 1 Korelasi Fitur terhadap Target	71
Gambar 4. 2 Kurva Loss dan Akurasi per Epoch.....	76
Gambar 4. 3 Confusion Matrix — SGD+Momentum.....	80
Gambar 4. 4 Confusion Matrix — RMSProp	82
Gambar 4. 5 confusion matrix - Adam.....	84
Gambar 4. 6 Confusion Matrix - HFO	86
Gambar 4. 7 Confusion Matrix - HFO Model Akademik	91

DAFTAR TABEL

Tabel 2. 1 Analisis Penelitian Terdahulu	21
Tabel 3. 1 Pemetaan Label Target ke Kode Numerik dan One-Hot Encoding.....	39
Tabel 3. 2 Pembagian Dataset.....	40
Tabel 3. 3 Arsitektur Multilayer Perceptron (MLP)	44
Tabel 3. 4 Parameter HFO	55
Tabel 3. 5 Parameter Pelatihan pada Skenario Perbandingan Optimizer	56
Tabel 4.1 Ringkasan Data Mentah Alumni Fakultas Sains dan Teknologi Angkatan Tahun 2009 – 2021	61
Tabel 4. 2 Ringkasan Dataset Alumni Fakultas Sains dan Teknologi Angkatan Tahun 2009 – 2021.....	63
Tabel 4. 3 Pembagian Dataset.....	67
Tabel 4. 4 Pemetaan Label Target ke Kode Numerik dan One-Hot Encoding.....	69
Tabel 4. 5 Distribusi Label	69
Tabel 4. 6 Ringkasan Perilaku Konvergensi Setiap Optimizer.....	77
Tabel 4. 7 Hasil Evaluasi Model DNN dengan SGD + Momentum	79
Tabel 4. 8 Classification Report SGD + Momentum	79
Tabel 4. 9 Hasil Evaluasi Model DNN dengan RMSProp	82
Tabel 4. 10 Classification Report RMSProp	82
Tabel 4. 11 Hasil Evaluasi Model DNN dengan Adam	84
Tabel 4. 12 Classification Report Adam	84
Tabel 4. 13 Hasil Evaluasi Model DNN dengan HFO	86
Tabel 4. 14 Classification Report HFO	86
Tabel 4. 15 Komparatif Kinerja Optimizer.....	88
Tabel 4. 16 Hasil Evaluasi Model DNN dengan Optimizer HFO (Model Akademik)	91
Tabel 4. 17 Classification Report HFO (Model Akademik).....	91
Tabel 4. 18 Komparatif Evaluasi Model Akademik dan Model Akademik + Non Akademik	94

Abstrak

Andy Irawan 2026. **Prediksi Predikat Kelulusan Mahasiswa Menggunakan *Deep Neural Network* dengan *Hessian-Free Optimization***. Tesis. Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing (I) Dr. Zainal Abidin, S.Kom., M. Kom. Pembimbing (II) Dr. Mohammad Jamhuri, M.Si.

Kata kunci : *Deep Neural Network*, *Multilayer Perceptron*, *Hessian-Free Optimization*, Studi Ablasi, Optimisasi Orde Kedua, Prediksi Predikat Kelulusan.

Prediksi predikat kelulusan mahasiswa merupakan kebutuhan strategis bagi perguruan tinggi dalam mendukung monitoring akademik dan pengambilan keputusan berbasis data. Penelitian ini bertujuan mengembangkan model prediksi menggunakan *Deep Neural Network* (DNN) dengan pendekatan optimisasi *Hessian-Free Optimization* (HFO), serta membandingkan kinerjanya dengan *optimizer* berbasis turunan orde pertama. Model yang digunakan berupa *Multilayer Perceptron* (MLP) dengan tiga *hidden layer* (19, 12, dan 9 neuron) beraktivasi ReLU dan *output layer softmax* untuk klasifikasi empat kelas predikat kelulusan. Fungsi *loss* yang digunakan adalah *categorical cross-entropy*. Pada pendekatan HFO, pembaruan parameter diperoleh dengan menyelesaikan sistem Newton $H(\theta)\Delta\theta = -\nabla L(\theta)$ menggunakan *Hessian-vector product* dan algoritma *Conjugate Gradient* tanpa membentuk matriks Hessian secara eksplisit. Evaluasi pada 1.386 data uji menunjukkan perbedaan kinerja antar *optimizer*. SGDM menghasilkan akurasi 80,16%, Adam 80,45%, RMSProp 81,10%, sedangkan HFO mencapai akurasi tertinggi sebesar 85,64% dengan F1-score 0,8358. Hasil ini mengindikasikan bahwa pendekatan *second-order* berpotensi memberikan konvergensi yang lebih stabil dan kualitas solusi yang lebih baik dibandingkan pendekatan *first-order* maupun *adaptive first-order* pada konteks data ini. Namun demikian, HFO gagal mengklasifikasikan kelas minoritas (Cukup dan Memuaskan) dengan *precision* dan *recall* nol, sehingga keunggulannya terutama terlihat pada kelas mayoritas (*Sangat Memuaskan* dan *Cumlaude*). Studi ablasi menunjukkan bahwa penggunaan variabel akademik saja menghasilkan akurasi 84,85% (F1-score 0,8281), sedangkan kombinasi variabel akademik dan non-akademik meningkatkan akurasi menjadi 85,64% (F1-score 0,8358), atau meningkat sebesar 0,79%. Temuan ini menunjukkan bahwa variabel akademik merupakan prediktor dominan, sementara variabel non-akademik memberikan kontribusi komplementer dalam meningkatkan stabilitas dan generalisasi model. Penelitian ini menyimpulkan bahwa optimisasi berbasis informasi kurvatur melalui HFO dapat meningkatkan performa prediksi pada data akademik multivariat, namun tetap memiliki keterbatasan signifikan pada data tidak seimbang. Model yang dihasilkan berpotensi dikembangkan sebagai sistem pendukung keputusan dalam monitoring capaian mahasiswa di perguruan tinggi, dengan catatan perlu ditambahkan mekanisme penanganan ketidakseimbangan kelas sebelum implementasi.

Abstract

Andy Irawan 2026. *Prediction of Student Graduation Predicates Using Deep Neural Network with Hessian-Free Optimization*. Master's Thesis. Master's Program in Informatics, Faculty of Science and Technology, State Islamic University of Maulana Malik Ibrahim Malang. Advisor (I) Dr. Zainal Abidin, S.Kom., M.Kom. Advisor (II) Dr. Mohammad Jamhuri, M.Si.

Keywords : Deep Neural Network, Multilayer Perceptron, Hessian-Free Optimization, Ablation Study, Second-Order Optimization, Graduation Honors Prediction.

Predicting student graduation predicates is a strategic need for higher education institutions to support academic monitoring and data-driven decision-making. This study aims to develop a predictive model using a Deep Neural Network (DNN) with a Hessian-Free Optimization (HFO) approach, and to compare its performance with first-order derivative-based optimizers. The proposed model employs a Multilayer Perceptron (MLP) architecture with three *hidden layers* (19, 12, and 9 neurons) using ReLU activation and a *softmax* output layer for four-class graduation predicate classification. The loss function used is categorical *cross-entropy*. In the HFO approach, parameter updates are obtained by solving the Newton system $H(\theta)\Delta\theta = -\nabla\mathcal{L}(\theta)$ using Hessian-vector products and the Conjugate Gradient algorithm without explicitly forming the Hessian matrix. Evaluation on 1,386 test samples reveals performance differences among optimizers. SGDM achieves an accuracy of 80.16%, Adam 80.45%, RMSProp 81.10%, while HFO achieves the highest accuracy of 85.64% with a F1-score of 0.8358. These results indicate that the second-order approach has the potential to provide more stable convergence and better solution quality compared to first-order and adaptive first-order approaches in the context of this data. However, HFO fails to classify minority classes (*Cukup* and *Memuaskan*) with zero precision and recall, so its advantage is primarily observed in the majority classes (*Sangat Memuaskan* and *Cumlaude*). An ablation study shows that using academic variables alone yields an accuracy of 84.85% (F1-score of 0.8281), while combining academic and non-academic variables increases accuracy to 85.64% (F1-score of 0.8358), representing an improvement of 0.79%. These findings indicate that academic variables are the dominant predictors, while non-academic variables provide complementary contributions in enhancing model stability and generalization. This study concludes that curvature-based optimization through HFO can improve prediction performance on multivariate academic data, but still has significant limitations on imbalanced data. The resulting model has the potential to be developed as a decision support system for monitoring student achievement in higher education, with the note that class imbalance handling mechanisms need to be added prior to implementation.

ملخص

آندي إيروان 2026. توقعات مسند تخرج الطلاب باستخدام ديب نيورال نيتوورك مع هيسيان فري أوبتيميزيشن. رسالة الماجستير. برنامج الماجستير في علم المعلوماتية ، كلية العلوم والتكنولوجيا ، الجامعة الإسلامية الحكومية مولانا مالك إبراهيم مالانغ. المرشد (I) دكتور زين العابدين ، المرشد (II) دكتور محمد جمهوري.

الكلمات الأساسية : ديب نيورال نيتوورك ، مالتى لاير بيرسبترون ، هيسيان فري أوبتيميزيشن ، دراسة الاستئصال ، التحسين من الدرجة الثانية ، توقعات تخرج الطلاب.

التنبؤ بمعايير تخرج الطلاب هو حاجة استراتيجية لمؤسسات التعليم العالي لدعم المراقبة الأكاديمية واتخاذ القرار القائم على البيانات. تهدف هذه الدراسة إلى تطوير نموذج تنبؤ باستخدام شبكة عصبية عميقة (DNN) مع نهج تحسين خال من هيسين (HFO)، ومقارنة أدائه مع المحسنات المعتمدة على المشتقات من الدرجة الأولى. يستخدم النموذج المقترح بنية Perceptron متعددة الطبقات (MLP) مع ثلاث طبقات مخفية (19، 12، 9 عصبونات) باستخدام تفعيل ReLU وطبقة إخراج softmax لتصنيف مسند التخرج بأربع فئات. دالة الخسارة المستخدمة هي الإنتروبيا التصنيفية المتقاطعة. في نهج HFO، يتم الحصول على تحديثات المعلمات بحل نظام نيوتن باستخدام حاصل ضرب متجه هيسي وخوارزمية التدرج المترافق دون تشكيل مصفوفة هيسي بشكل صريح. يكشف التقييم على 1,386 عينة اختبار عن فروق في الأداء بين المحسنين. تحقق SGDM دقة 80.16٪، ADAM 80.45٪، RMSProp 81.10٪، بينما تحقق HFO أعلى دقة بنسبة 85.64٪ مع درجة F1 تبلغ 0.8358. تشير هذه النتائج إلى أن النهج من الدرجة الثانية لديه القدرة على توفير تقارب أكثر استقراراً وجودة حل أفضل مقارنة بالنهج من الدرجة الأولى والتكيفية من الدرجة الأولى في سياق هذه البيانات. ومع ذلك، يفشل HFO في تصنيف فئات الأقليات ($H(\theta)\Delta\theta = -\nabla L(\theta)$ كوكاب وميمواكان) بدقة واستدعاء معدومين، لذا تلاحظ ميزته بشكل أساسي في الفئات الأغلبية (سانغات ميمواسكان وكوملود). تظهر دراسة الاستئصال أن استخدام المتغيرات الأكاديمية وحده يعطي دقة تبلغ 84.85٪ (درجة F1 0.8281)، بينما يجمع بين المتغيرات الأكاديمية وغير الأكاديمية الدقة إلى 85.64٪ (درجة F1 0.8358)، مما يمثل تحسناً بنسبة 0.79٪. تشير هذه النتائج إلى أن المتغيرات الأكاديمية هي المتنبؤات السائدة، بينما توفر المتغيرات غير الأكاديمية مساهمات تكميلية لتعزيز استقرار النموذج وتعميمه. خلصت هذه الدراسة إلى أن التحسين القائم على الانحناء من خلال HFO يمكن أن يحسن أداء التنبؤ على البيانات الأكاديمية متعددة المتغيرات، لكنه لا يزال يواجه قيوداً كبيرة على البيانات غير المتوازنة. النموذج الناتج لديه القدرة على أن يطور كنظام دعم اتخاذ قرار لمراقبة تحصيل الطلاب في التعليم العالي، مع الإشارة إلى ضرورة إضافة آليات التعامل مع عدم توازن الطبقات قبل التنفيذ.

BAB I

PENDAHULUAN

1.1. Latar Belakang

Pendidikan tinggi memiliki peran strategis dalam menghasilkan lulusan yang tidak hanya unggul secara akademik, tetapi juga mampu menjawab tantangan era digital dan kompleksitas global. Salah satu indikator yang digunakan untuk mengukur keberhasilan pendidikan tinggi adalah predikat kelulusan mahasiswa, yang mencerminkan pencapaian akademik sepanjang masa studi serta menjadi tolok ukur mutu penyelenggaraan pendidikan di suatu institusi (Yaacob *et al.*, 2019). Predikat ini tidak hanya berdampak pada reputasi lembaga, tetapi juga berpengaruh terhadap peluang karier lulusan dan tingkat akreditasi program studi (Shahiri *et al.*, 2015).

Saat ini, pemangku kepentingan di lingkungan pendidikan tinggi seperti dosen, dosen wali, ketua program studi, wakil dekan, dan dekan menghadapi tantangan besar dalam memprediksi capaian akhir mahasiswa, terutama ketika mahasiswa telah memasuki semester kelima. Belum tersedia sistem yang mampu memberikan gambaran dini mengenai predikat kelulusan mahasiswa, apakah lulus dengan predikat *cumlaude*, sangat memuaskan, memuaskan, atau cukup. Ketidakmampuan ini berdampak pada minimnya intervensi akademik yang bersifat preventif maupun strategis, padahal masa studi mahasiswa sudah lebih dari setengah jalan. Jika capaian akhir dapat diprediksi sejak dini, para pemangku kepentingan akan lebih mudah merancang langkah pembinaan, peringatan dini, atau dukungan belajar yang dibutuhkan agar mahasiswa dapat lulus tepat waktu dengan capaian optimal.

Berbagai penelitian menunjukkan bahwa keberhasilan mahasiswa dalam mencapai predikat kelulusan tertentu dipengaruhi oleh kombinasi faktor akademik dan non-akademik. Faktor akademik meliputi indeks prestasi kumulatif (IPK), nilai mata kuliah dasar, dan kinerja per semester (Widaningsih, 2019), sedangkan faktor non-akademik mencakup jenis kelamin, jalur seleksi masuk, keaktifan organisasi, dan karakteristik demografis lainnya (Nurrohmat, 2015; Rudy Hendrawan *et al.*, 2022). Penelitian lain juga menemukan bahwa indikator seperti pengalaman organisasi (Rudy Hendrawan *et al.*, 2022), log aktivitas pembelajaran daring (Indahyanti *et al.*, 2022), dan peran sebagai asisten praktikum (Nurrohmat, 2015) turut memberikan pengaruh terhadap capaian akademik mahasiswa.

Seiring dengan semakin kompleksnya variabel yang memengaruhi capaian akademik, pendekatan *machine learning* dalam bidang *educational data mining* (EDM) telah banyak digunakan untuk melakukan prediksi berbasis pola data. Algoritma seperti *Naïve Bayes*, *Decision Tree*, *K-Nearest Neighbor* (KNN), dan *Support Vector Machine* (SVM) telah diterapkan secara luas untuk memprediksi predikat kelulusan maupun performa akademik secara umum (Mustakim & Oktaviani F, 2016; Nasution *et al.*, 2023; Wibowo & Rohman, 2022; Widaningsih, 2019). Penelitian oleh Zulfiqar *et al.* (2020) menunjukkan bahwa kombinasi *Decision Tree* dan *Naïve Bayes* dapat menghasilkan akurasi prediksi sebesar 72,73%. Sementara itu, Ofori *et al.* (2020) membuktikan bahwa model *Neural Network* mampu mencapai akurasi hingga 95,34% dalam memprediksi performa akademik berdasarkan data nilai dan faktor sosial ekonomi.

Namun demikian, sebagian besar penelitian tersebut masih memiliki dua keterbatasan utama. Pertama, mayoritas penelitian masih mengandalkan variabel akademik semata dan mengabaikan faktor non-akademik kontekstual yang khas di lingkungan perguruan tinggi Islam, seperti pengalaman mondok di pesantren dan kemampuan bahasa Arab. Kedua, penelitian-penelitian tersebut masih menggunakan algoritma optimisasi konvensional berbasis turunan pertama (*first-order*) seperti *Stochastic Gradient Descent with Momentum* (SGDM), *Root Mean Square Propagation* (RMSProp), dan *Adaptive Moment Estimation* (Adam), yang memiliki keterbatasan dalam hal konvergensi dan rentan terjebak pada *local minima*.

Keterbatasan pertama berkaitan dengan variabel prediktor. Sejauh ini belum banyak penelitian yang secara eksplisit menyoroti kontribusi latar belakang pendidikan keislaman seperti pengalaman mondok di pesantren dan kemampuan bahasa Arab terhadap prediksi capaian akademik, khususnya dalam konteks perguruan tinggi Islam. Padahal, variabel-variabel tersebut berpotensi memberikan informasi tambahan yang bermanfaat, terutama pada tahap awal sebelum data akademik semester terkumpul.

Keterbatasan kedua berkaitan dengan metode optimisasi. Penelitian Suleman & Palupi (2023) misalnya, menggunakan *Deep Neural Network* (DNN) untuk prediksi akademik dan memperoleh akurasi sebesar 73%, tetapi belum menyertakan eksperimen dengan optimisasi tingkat lanjut. Sampai saat ini, belum ditemukan penelitian yang menerapkan *Hessian-Free Optimization* (HFO) secara eksplisit dalam konteks EDM, padahal metode optimisasi orde kedua (*second-order*) ini berpotensi memanfaatkan informasi kurvatur fungsi *loss* untuk menghasilkan arah pembaruan parameter yang lebih informatif dibandingkan metode berbasis gradien orde pertama, sehingga dapat

mempercepat konvergensi dan meningkatkan stabilitas pelatihan DNN (Defazio & Bottou, 2019; Martens, 2010).

Sejalan dengan semangat integrasi antara sains dan Islam yang menjadi karakteristik utama perguruan tinggi Islam, penelitian ini tidak hanya bersifat teknis atau instrumental, tetapi juga mengandung dimensi filosofis yang mendalam. Islam memandang ilmu sebagai jalan pencerahan yang memandu manusia mengenali hakikat dirinya, alam semesta, dan Tuhannya. Oleh karena itu, pengembangan ilmu pengetahuan dan teknologi, termasuk dalam bidang kecerdasan buatan dan EDM, tidak dapat dipisahkan dari nilai-nilai spiritual dan etika keislaman. Al-Qur'an secara eksplisit mengangkat kedudukan ilmu dan orang-orang yang menguasainya dalam berbagai ayat. Firman Allah SWT dalam QS. Al-Mujadilah ayat 11 menyatakan:

يَرْفَعُ اللَّهُ الَّذِينَ آمَنُوا مِنْكُمْ وَالَّذِينَ أُوتُوا الْعِلْمَ دَرَجَاتٍ

“Allah akan meninggikan orang-orang yang beriman di antara kamu dan orang-orang yang diberi ilmu beberapa derajat.” (QS. Al-Mujadilah: 11)

Ayat ini menunjukkan bahwa keilmuan yang ditopang oleh keimanan akan mengangkat martabat manusia dan menjadi pondasi utama dalam membangun peradaban yang adil, beradab, dan berkelanjutan. Oleh karena itu, pendekatan ilmiah seperti pemanfaatan algoritma *deep learning* dalam penelitian ini harus diarahkan untuk kemaslahatan umat dan penguatan sistem pendidikan yang holistik.

Berdasarkan identifikasi dua keterbatasan tersebut, penelitian ini mengusulkan pengembangan model prediksi predikat kelulusan mahasiswa menggunakan DNN yang dioptimalkan dengan HFO, serta mengintegrasikan variabel akademik dan non-akademik khas perguruan tinggi Islam. Dengan demikian, penelitian ini bertujuan

untuk mengisi *gap* pada aspek penggunaan HFO dalam domain EDM sekaligus memperluas perspektif pemodelan prediktif dengan mengintegrasikan variabel kontekstual yang selama ini belum banyak dieksplorasi dalam studi prediksi akademik berbasis *deep learning*.

1.2. Pernyataan Masalah

Pernyataan masalah dalam penelitian ini adalah sebagai berikut:

1. Performa model prediksi menggunakan *Neural Network* dengan algoritma *Hessian-Free Optimization* (HFO) perlu dibandingkan dengan algoritma optimisasi konvensional (SGDM, RMSProp, dan Adam) dalam memprediksi predikat kelulusan mahasiswa.
2. Kontribusi kombinasi data akademik dan non-akademik (seperti asal sekolah, pengalaman mondok di pesantren, kemampuan berbahasa Arab dan Inggris, jalur seleksi masuk, kemampuan komputer, dan lain-lain) terhadap prediksi predikat kelulusan mahasiswa di perguruan tinggi Islam perlu diidentifikasi.

1.3. Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Mengembangkan model prediksi predikat kelulusan mahasiswa berbasis *Deep Neural Network* (DNN) yang dioptimalkan menggunakan algoritma *Hessian-Free Optimization* (HFO).

2. Membandingkan performa model DNN dengan HFO terhadap model DNN dengan algoritma optimisasi konvensional (SGDM, RMSProp, dan Adam) dalam memprediksi predikat kelulusan mahasiswa.
3. Mengidentifikasi kontribusi relatif faktor-faktor akademik dan non-akademik (termasuk pengalaman mondok, kemampuan bahasa Arab, dan lain-lain) terhadap prediksi predikat kelulusan mahasiswa.

1.4. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Memberikan kontribusi terhadap pengembangan metode optimisasi lanjutan dalam pelatihan neural network, serta memperluas cakupan penelitian EDM dengan mempertimbangkan faktor non-akademik.
2. Memberikan model prediktif yang dapat digunakan oleh institusi pendidikan untuk mendeteksi mahasiswa berisiko, membantu pengambilan kebijakan akademik, dan menyusun strategi pembinaan yang lebih terarah.

1.5. Batasan Masalah

Penelitian ini memiliki batasan-batasan yang perlu dijelaskan agar fokus penelitian tetap terjaga dan sesuai dengan tujuan yang ingin dicapai. Adapun batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Institusi dan Data: Penelitian ini terbatas pada data alumni Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang angkatan tahun 2009–2021. Oleh karena itu, hasil penelitian tidak dapat digeneralisasikan

secara otomatis ke perguruan tinggi lain, baik Islam maupun non-Islam, tanpa pengujian lebih lanjut pada konteks masing-masing.

2. Data yang Digunakan: Penelitian ini menggunakan data akademik berupa nilai Indeks Prestasi Semester (IPS) 1 s.d. 4 serta data non-akademik mahasiswa yang mencakup faktor-faktor seperti asal sekolah, pengalaman mondok di pesantren, kemampuan berbahasa Arab dan Inggris, jalur seleksi masuk, kemampuan komputer, dan jurusan. Data yang digunakan terbatas pada informasi yang tersedia dalam sistem administrasi akademik (SIKAD) di institusi terkait.
3. Arsitektur DNN dan Algoritma yang Digunakan: Penelitian menggunakan arsitektur *Deep Neural Network* (DNN) yang mengadopsi struktur *Multilayer Perceptron* (MLP) *feedforward*, terdiri dari satu lapisan input, tiga lapisan tersembunyi (*hidden layers*) dengan jumlah neuron masing-masing 19, 12, dan 9, serta satu lapisan *output*. Proses pelatihan dilakukan dengan skema *backpropagation* yang dioptimalkan menggunakan HFO dan dibandingkan dengan algoritma optimisasi konvensional (SGDM, RMSProp, dan Adam). Algoritma optimisasi lain selain yang disebutkan tidak dipertimbangkan dalam penelitian ini.

BAB II

TINJAUAN PUSTAKA

2.1. Predikat Kelulusan Mahasiswa

2.1.1. Pendidikan Tinggi dan Predikat Kelulusan

Pendidikan tinggi berperan penting dalam mempersiapkan sumber daya manusia yang tidak hanya unggul secara akademik, tetapi juga adaptif terhadap perubahan sosial, teknologi, dan ekonomi global. Perguruan tinggi dituntut untuk menghasilkan lulusan yang berkompeten melalui sistem penjaminan mutu internal dan eksternal. Salah satu indikator penting dalam mengevaluasi mutu pendidikan tinggi adalah predikat kelulusan mahasiswa, yang biasanya dikategorikan berdasarkan nilai Indeks Prestasi Kumulatif (IPK) menjadi predikat seperti cumlaude, sangat memuaskan, memuaskan dan cukup (UIN Malang, 2024).

Predikat kelulusan tidak hanya berdampak terhadap reputasi akademik institusi, tetapi juga berhubungan erat dengan kesempatan karier dan daya saing lulusan di pasar kerja (Alturki *et al.*, 2021). Beberapa studi menegaskan bahwa lulusan dengan predikat lebih tinggi memiliki peluang yang lebih besar untuk memperoleh pekerjaan lebih cepat dan dengan gaji awal yang lebih tinggi dibandingkan lulusan dengan predikat lebih rendah (Yaacob *et al.*, 2019).

Predikat kelulusan juga menjadi salah satu indikator dalam penilaian akreditasi program studi dan institusi oleh lembaga akreditasi seperti BAN-PT di Indonesia maupun ASIIN di tingkat internasional. Semakin tinggi persentase mahasiswa yang

lulus dengan predikat cumlaude, semakin baik persepsi kualitas program tersebut di mata regulator dan masyarakat.

Predikat kelulusan juga dianggap mencerminkan keberhasilan perguruan tinggi dalam menyelenggarakan pengelolaan akademik yang efektif, termasuk kurikulum, layanan pembelajaran, dan pembinaan mahasiswa (Shahiri *et al.*, 2015). Kemampuan untuk memprediksi predikat kelulusan sejak dini menjadi sangat penting sebagai bagian dari manajemen risiko akademik, guna memungkinkan intervensi yang lebih tepat waktu dalam bentuk pembinaan tambahan atau program pengayaan.

Dalam konteks perguruan tinggi Islam, seperti di UIN Maulana Malik Ibrahim Malang, pengukuran prestasi akademik mahasiswa tidak hanya didasarkan pada capaian akademik formal, tetapi juga mempertimbangkan nilai-nilai religius dan moral yang dibentuk selama masa studi. Sehingga, faktor-faktor non-akademik, seperti pengalaman pendidikan keislaman di jenjang SLTA atau pesantren, dapat berpotensi menjadi prediktor penting dalam menentukan capaian akhir mahasiswa. Namun, integrasi faktor akademik dan non-akademik ke dalam model prediksi masih jarang dieksplorasi secara komprehensif, khususnya dengan pendekatan *machine learning* canggih.

2.1.2. Faktor-Faktor yang Mempengaruhi Capaian Akademik

Capaian akademik mahasiswa merupakan kombinasi kompleks antara berbagai faktor yang bersifat akademik maupun non-akademik. Pemahaman tentang faktor-faktor ini penting untuk merancang strategi pembelajaran, pembinaan, dan intervensi yang efektif di lingkungan pendidikan tinggi.

a. Faktor Akademik

Faktor akademik adalah variabel yang secara langsung berkaitan dengan aktivitas pembelajaran formal mahasiswa. Indeks Prestasi Kumulatif (IPK) menjadi salah satu indikator utama capaian akademik, yang terbentuk dari akumulasi nilai mata kuliah yang diambil sepanjang masa studi.

Beberapa faktor akademik lain yang mempengaruhi capaian kelulusan antara lain:

- Nilai mata kuliah dasar seperti Matematika, Bahasa Inggris, dan mata kuliah kompetensi dasar program studi (Widaningsih, 2019).
- Kinerja per semester, dimana konsistensi nilai tinggi di tiap semester lebih berpeluang menghasilkan predikat cumlaude dibandingkan pola nilai yang fluktuatif (Mustakim & Oktaviani F, 2016).

Penelitian oleh Wibowo & Rohman, (2022) menunjukkan bahwa prestasi di mata kuliah tahun-tahun awal memiliki korelasi kuat dengan keberhasilan akhir studi mahasiswa.

b. Faktor Non-Akademik

Selain aspek akademik, banyak studi menunjukkan bahwa faktor non-akademik berperan penting dalam mempengaruhi capaian akademik mahasiswa, di antaranya:

- Jenis kelamin: beberapa penelitian menemukan bahwa perempuan cenderung memiliki capaian akademik lebih tinggi dibandingkan laki-laki, meskipun hal ini dapat bervariasi berdasarkan bidang studi (Rudy Hendrawan *et al.*, 2022).

- Asal sekolah: Latar belakang sekolah menengah atas, baik dari segi kualitas maupun kurikulum, dapat mempengaruhi kesiapan akademik mahasiswa di perguruan tinggi (Nurrohmah, 2015).
- Pengalaman mondok di pesantren: Dalam konteks perguruan tinggi Islam, pengalaman belajar di pesantren memperkuat kedisiplinan, kemandirian, dan keterampilan manajemen waktu, yang berdampak positif terhadap prestasi akademik (Indahyanti *et al.*, 2022).
- Kemampuan berbahasa asing: Mahasiswa dengan kemampuan bahasa Inggris yang baik biasanya lebih mudah mengakses literatur akademik global, sehingga mendukung performa akademik mereka (Rudy Hendrawan *et al.*, 2022).
- Jalur seleksi masuk: Mahasiswa yang diterima melalui jalur prestasi (seperti SNMPTN atau jalur undangan) cenderung memiliki dasar akademik yang lebih kuat dibandingkan dengan jalur reguler (Mustakim & Oktaviani F, 2016).
- Kemampuan Komputer: Di era digital, keterampilan dalam mengoperasikan perangkat lunak akademik dan sistem pembelajaran daring menjadi faktor pendukung keberhasilan akademik (Nasution *et al.*, 2023).

2.1.3. Educational Data Mining (EDM)

a. Definisi EDM

EDM adalah bidang interdisipliner yang berfokus pada pengembangan metode untuk mengeksplorasi data unik yang berasal dari lingkungan pendidikan, dengan tujuan untuk memahami lebih dalam tentang bagaimana peserta didik belajar dan bagaimana pengaturan pendidikan bisa diperbaiki (Romero & Ventura, 2010). Bidang

EDM mulai berkembang sebagai disiplin tersendiri pada awal 2000-an dan secara institusional berkembang melalui konferensi pertama International Conference on Educational Data Mining (EDM) diadakan pada tahun 2008 kemudian didirikan Jurnal Journal of Educational Data Mining (JEDM) pada tahun 2009. Munculnya organisasi International Educational Data Mining Society (IEDMS) ikut memperkuat posisi EDM sebagai bidang riset independen data mining dalam pengembangan pendidikan.

Menurut Baker & Yacef, (2009), EDM menggunakan teknik data mining, machine learning, statistik, dan psikometri untuk mengekstraksi pola dari data pendidikan, seperti data nilai, data perilaku pembelajaran online, hingga data demografi mahasiswa. Intinya, EDM adalah proses menemukan pengetahuan tersembunyi dari data pendidikan untuk mendukung pengambilan keputusan yang lebih baik.

b. Metode-metode yang umum digunakan dalam EDM

Beberapa teknik data mining yang populer dalam EDM antara lain:

- Classification: memprediksi kategori hasil belajar (contoh: kelulusan dengan predikat Cumlaude atau tidak).
- Clustering: mengelompokkan mahasiswa berdasarkan kemiripan perilaku belajar.
- Association Rule Mining: menemukan pola asosiatif antara faktor-faktor yang mempengaruhi prestasi.
- Regression: memprediksi nilai numerik seperti IPK akhir.

Metode populer:

- Decision Tree
- Naïve Bayes

- Support Vector Machine (SVM)
- K-Nearest Neighbors (KNN)
- Artificial Neural Network (ANN)

Studi: (Nasution et al., 2023; Wibowo & Rohman, 2022)

2.1.4. Deep Neural Network

DNN adalah salah satu jenis model ANN yang memiliki banyak lapisan tersembunyi (*hidden layers*) di antara lapisan input dan output. DNN adalah bagian dari keluarga besar Deep Learning yang terkenal karena kemampuannya dalam memodelkan hubungan non-linear dan menangkap pola-pola yang sangat kompleks dalam data yang tidak dapat dipelajari oleh model-model linear tradisional (Goodfellow and Yoshua Bengio, 2016).

a. Struktur Dasar DNN

Struktur dasar dari DNN terdiri dari beberapa komponen utama, yaitu lapisan input, *hidden layers*, dan lapisan output.

- Lapisan Input: Lapisan pertama pada DNN menerima data mentah yang akan diproses lebih lanjut. Setiap node dalam lapisan input mewakili fitur individual dari data yang dimasukkan ke dalam model. Sebagai contoh, jika data input berupa nilai akademik mahasiswa (seperti IPS semester), maka setiap nilai IPS tersebut akan menjadi fitur yang diterima oleh lapisan input.
- Lapisan Tersembunyi: Lapisan ini terdiri dari banyak neuron yang berfungsi untuk memproses data yang diterima dari lapisan input dan menghasilkan representasi yang lebih kompleks. Jumlah lapisan tersembunyi pada DNN sangat bervariasi,

dan semakin banyak lapisan yang digunakan, semakin dalam model tersebut dalam hal representasi pola data yang lebih kompleks. Setiap neuron pada lapisan tersembunyi mengkombinasikan inputnya dengan bobot (weights), kemudian mengubah hasilnya melalui fungsi aktivasi (activation function) yang akan diteruskan ke lapisan berikutnya.

- Lapisan Output: Lapisan output adalah lapisan terakhir yang menghasilkan prediksi atau keputusan dari model. Pada model prediksi kelulusan mahasiswa, misalnya, lapisan output akan mengklasifikasikan predikat kelulusan mahasiswa berdasarkan data yang diberikan.

Secara keseluruhan, DNN dapat memiliki banyak lapisan tersembunyi, dan semakin dalam struktur jaringan, semakin baik kemampuannya dalam menangkap pola yang sangat kompleks dalam data (Yann Lecun, Yoshua Bengio, 2016).

DNN adalah fungsi parametrik non-linier yang membangun pemetaan dari $\mathbf{x} \in \mathbb{R}^d$ ke distribusi kelas $\hat{\mathbf{y}} \in \mathbb{R}^K$ melalui komposisi fungsi-fungsi linier dan non-linier. Model multilayer perceptron (MLP) Feedforward dengan L lapisan dinyatakan sebagai:

$$\mathbf{a}^{(0)} = \mathbf{x}, \quad \mathbf{z}^{(l)} = \mathbf{W}^{(l)}\mathbf{a}^{(l-1)} + \mathbf{b}^{(l)}, \quad \mathbf{a}^{(l)} = \sigma^{(l)}(\mathbf{z}^{(l)}), \quad l = 1, \dots, L$$

Fungsi aktivasi $\sigma^{(l)}$ umumnya adalah ReLU: $\sigma(z) = \max(0, z)$ untuk $l < L$, dan *softmax* untuk lapisan output:

$$\hat{\mathbf{y}} = \text{Softmax}(\mathbf{z}^{(L)}) = \begin{bmatrix} \frac{e^{z_1}}{\sum_{j=1}^K e^{z_j}} \\ \frac{e^{z_2}}{\sum_{j=1}^K e^{z_j}} \\ \vdots \\ \frac{e^{z_K}}{\sum_{j=1}^K e^{z_j}} \end{bmatrix} \dots\dots\dots(\text{II.1})$$

Fungsi loss untuk pelatihan jaringan adalah:

$$\text{Loss} = -\sum_{k=1}^K y_k \log(\hat{y}_k) \dots\dots\dots(\text{II.2})$$

Pada masalah Klasifikasi Multiclass digunakan fungsi *Argmax* sebagai berikut:

$$\hat{c} = \text{argmax}(\hat{\mathbf{y}}) \dots\dots\dots(\text{II.3})$$

dengan

$\hat{c}$ = kelas prediksi

(Lihat: (Goodfellow and Yoshua Bengio, 2016; Yann Lecun, Yoshua Bengio, 2016))

b. Algoritma Optimisasi dalam Deep Neural Network

Optimisasi dalam DNN merupakan tahap penting yang menentukan seberapa baik model dapat mempelajari dan menyesuaikan bobot (weights) pada lapisan-lapisan tersembunyinya. Algoritma optimisasi bertanggung jawab untuk meminimalkan fungsi kerugian (*loss function*) selama proses pelatihan. Pembaruan bobot secara umum dilakukan menggunakan rumus:

$$\theta_{t+1} = \theta_t - \eta \nabla L(\theta_t) \dots\dots\dots(\text{II.3})$$

dimana:

θ_t adalah parameter (bobot dan bias),

η adalah *learning rate*,
 $\nabla L(\theta_t)$ adalah turunan fungsi loss terhadap parameter.

Beberapa algoritma optimisasi konvensional yang sering digunakan dalam pelatihan DNN adalah SGDM, RMSProp, dan Adam. Setiap algoritma ini memiliki karakteristik tersendiri, dengan kelebihan dan keterbatasannya masing-masing.

1) *Stochastic Gradient Descent with Momentum*

SGDM adalah salah satu algoritma optimisasi yang paling sederhana dan paling sering digunakan dalam pelatihan model neural network. SGDM memperbarui bobot model berdasarkan gradien fungsi *Loss* yang dihitung pada satu sampel data atau subset kecil data, yang disebut mini-batch dalam setiap iterasi serta Momentum menambahkan “memori” dari arah pergerakan sebelumnya untuk mengurangi osilasi dan mempercepat konvergensi.

Update parameter SGDM didefinisikan sebagai berikut:

$$\theta_{t+1} = \theta_t + m_{t+1} \dots\dots\dots (II.4)$$

Dimana

$$m_{t+1} = \mu m_t - \eta \nabla L(\theta_t) \dots\dots\dots (II.5)$$

dengan μ (μ): koefisien momentum (biasanya antara 0.9 – 0.99), η adalah *learning rate*.

2) *Root Mean Square Propagation*

RMSProp adalah algoritma optimisasi yang dikembangkan untuk mengatasi kekurangan SGDM dalam hal fluktuasi yang besar. RMSProp menggunakan nilai rata-rata bergerak dari gradien untuk memperbarui bobot, yang membuat algoritma ini lebih

stabil dan mampu menghindari pergerakan yang terlalu besar pada satu dimensi atau parameter.

$$v_t = \gamma v_{t-1} + (1 - \gamma)(\nabla L(\theta_t))^2 \dots\dots\dots (\text{II.6})$$

Update parameter RMSProp didefinisikan sebagai berikut:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v_t + \epsilon}} \nabla L(\theta_t) \dots\dots\dots (\text{II.7})$$

dimana γ adalah hyperparameter decay (biasanya 0.9), dan ϵ adalah konstanta kecil untuk mencegah pembagian dengan nol.

3) *Adaptive Moment Estimation*

Adam adalah salah satu algoritma optimisasi yang sangat populer dan sering digunakan dalam pelatihan DNN. Adam menggabungkan kelebihan dari RMSProp dan Momentum dengan memperhitungkan rata-rata pergerakan gradien pertama (momentum) dan gradien kedua (kecepatan perubahan gradien). Dengan cara ini, Adam dapat memperbaiki proses pembaruan bobot dengan cara yang lebih adaptif, tergantung pada arah gradien dan perubahan dalam setiap parameter.

Update parameter Adam didefinisikan oleh persamaan berikut:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \nabla L(\theta_t) \dots\dots\dots (\text{II.8})$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) (\nabla L(\theta_t))^2 \dots\dots\dots (\text{II.9})$$

Dengan estimasi koreksi bias:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \dots\dots\dots (\text{II.10})$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \dots\dots\dots (\text{II.11})$$

Maka update parameter Adam adalah:

$$\theta_{t+1} = \theta_t - \frac{\eta \hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \dots\dots\dots (II.12)$$

4) Hessian-Free Optimization

Metode optimisasi *first-order* seperti SGDM, RMSProp, dan Adam hanya memanfaatkan informasi gradien ($\nabla \mathcal{L}(\theta)$), yaitu kemiringan fungsi *loss* di titik saat ini. Analoginya seperti seseorang yang berjalan menuruni bukit dalam kabut tebal, ia hanya merasakan kemiringan di tempat kakinya berpijak, tetapi tidak tahu bagaimana bentuk lereng di depannya.

Metode orde kedua (*second-order*) seperti Newton dan HFO memanfaatkan informasi kelengkungan (curvature) melalui matriks Hessian ($H(\theta)$), yang menggambarkan bagaimana gradien berubah jika kita bergerak. Analoginya, orang tersebut sekarang memiliki peta kontur yang menunjukkan tidak hanya kemiringan saat ini, tetapi juga bagaimana kemiringan akan berubah ke depan. Dengan informasi ini, ia bisa memilih arah yang lebih langsung menuju lembah.

Ide dasar HFO (dan metode Newton pada umumnya) adalah mendekati fungsi *loss* dengan fungsi kuadratik (parabola) di sekitar titik saat ini. Fungsi kuadratik lebih mudah diminimalkan karena bentuknya sederhana.

Aproksimasi kuadratik lokal dari fungsi *loss* $\mathcal{L}(\theta)$ di sekitar titik θ dinyatakan sebagai:

$$m_{\theta}(d) = \mathcal{L}(\theta) + \nabla \mathcal{L}(\theta)^{\top} d + \frac{1}{2} d^{\top} H(\theta) d \dots\dots\dots (II.13)$$

$\mathcal{L}(\theta)$: Nilai *loss* saat ini
 $\nabla \mathcal{L}(\theta)^{\top} d$: Kontribusi gradien (kemiringan)
 $\frac{1}{2} d^{\top} H(\theta) d$: Kontribusi Hessian (kelengkungan)

Tujuan aproksimasi kuadratik lokal, mencari d (arah langkah) yang membuat $m_\theta(d)$ sekecil mungkin. Untuk mencari d yang meminimalkan $m_\theta(d)$, kita turunkan $m_\theta(d)$ terhadap d dan samakan dengan nol:

$$\frac{d}{dd} m_\theta(d) = \nabla \mathcal{L}(\theta) + H(\theta)d = 0$$

Sehingga diperoleh sistem Newton:

$$H(\theta)d = -\nabla \mathcal{L}(\theta) \dots\dots\dots (II.14)$$

Sistem ini mengatakan bahwa arah langkah d yang optimal adalah solusi dari persamaan linear di atas. Jika fungsi *loss* benar-benar berbentuk parabola sempurna (kuadratik murni), maka satu langkah Newton akan langsung mencapai titik minimum.

Meskipun elegan secara matematis, metode Newton konvensional memiliki dua masalah besar dalam DNN:

1. Matriks Hessian $H(\theta)$ berukuran $p \times p$, dengan p adalah jumlah parameter (bisa jutaan). Menyimpan matriks $p \times p$ (triliunan elemen) tidak mungkin.
2. Menghitung H^{-1} membutuhkan waktu yang cukup lama dan komputasi yang berat dan tidak mungkin dilakukan untuk DNN skala besar.

HFO mengatasi kedua masalah di atas dengan tidak pernah membentuk matriks Hessian secara eksplisit. Sebagai gantinya, HFO hanya menghitung hasil kali antara Hessian dengan suatu vektor (disebut *Hessian-vector product* atau HVP), yaitu:

$$H(\theta)v = \nabla_\theta (\nabla \mathcal{L}(\theta)^\top v) \dots\dots\dots (II.15)$$

Identitas ini (Pearlmutter, 1994) memungkinkan kita menghitung Hv dengan biaya komputasi hanya 2–3 kali lipat dari perhitungan gradien, bukan $O(p^2)$.

Sistem Newton murni $H(\theta)d = -\nabla\mathcal{L}(\theta)$ dapat menjadi tidak stabil jika matriks Hessian tidak *positive definite* (cekung atau datar). Untuk mengatasi ini, HFO modern menambahkan parameter damping $\lambda > 0$:

$$(H(\theta) + \lambda I)d = -g(\theta) \dots\dots\dots (II.16)$$

Parameter λ berfungsi ganda, yaitu:

1. Memastikan sistem solvable (matriks menjadi *positive definite*)
2. Mengontrol keagresifan (λ kecil = agresif/Newton-like, λ besar = konservatif/gradien-like)

Sistem $(H(\theta) + \lambda I)d = -g(\theta)$ diselesaikan secara iteratif menggunakan

Conjugate Gradient (CG) . CG sangat cocok karena:

- Hanya membutuhkan hasil kali matriks-vektor ($(H + \lambda I)v$) $\rightarrow$ bisa menggunakan HVP
- Tidak perlu menyimpan matriks H secara eksplisit
- Konvergen dalam jumlah iterasi yang relatif kecil (*truncated CG*)

2.2. Penelitian Terkait

Beberapa penelitian terdahulu yang relevan dengan topik prediksi kelulusan mahasiswa, khususnya yang menggunakan metode machine learning seperti DNN dan algoritma optimisasi, serta relevansi penelitian-penelitian tersebut terhadap penelitian yang sedang dilakukan. Hasil analisis terhadap berbagai artikel dan jurnal sebagaimana Tabel 2.1., penulis menemukan beberapa gap yang perlu ditangani dalam penelitian ini.

Tabel 2. 1 Analisis Penelitian Terdahulu

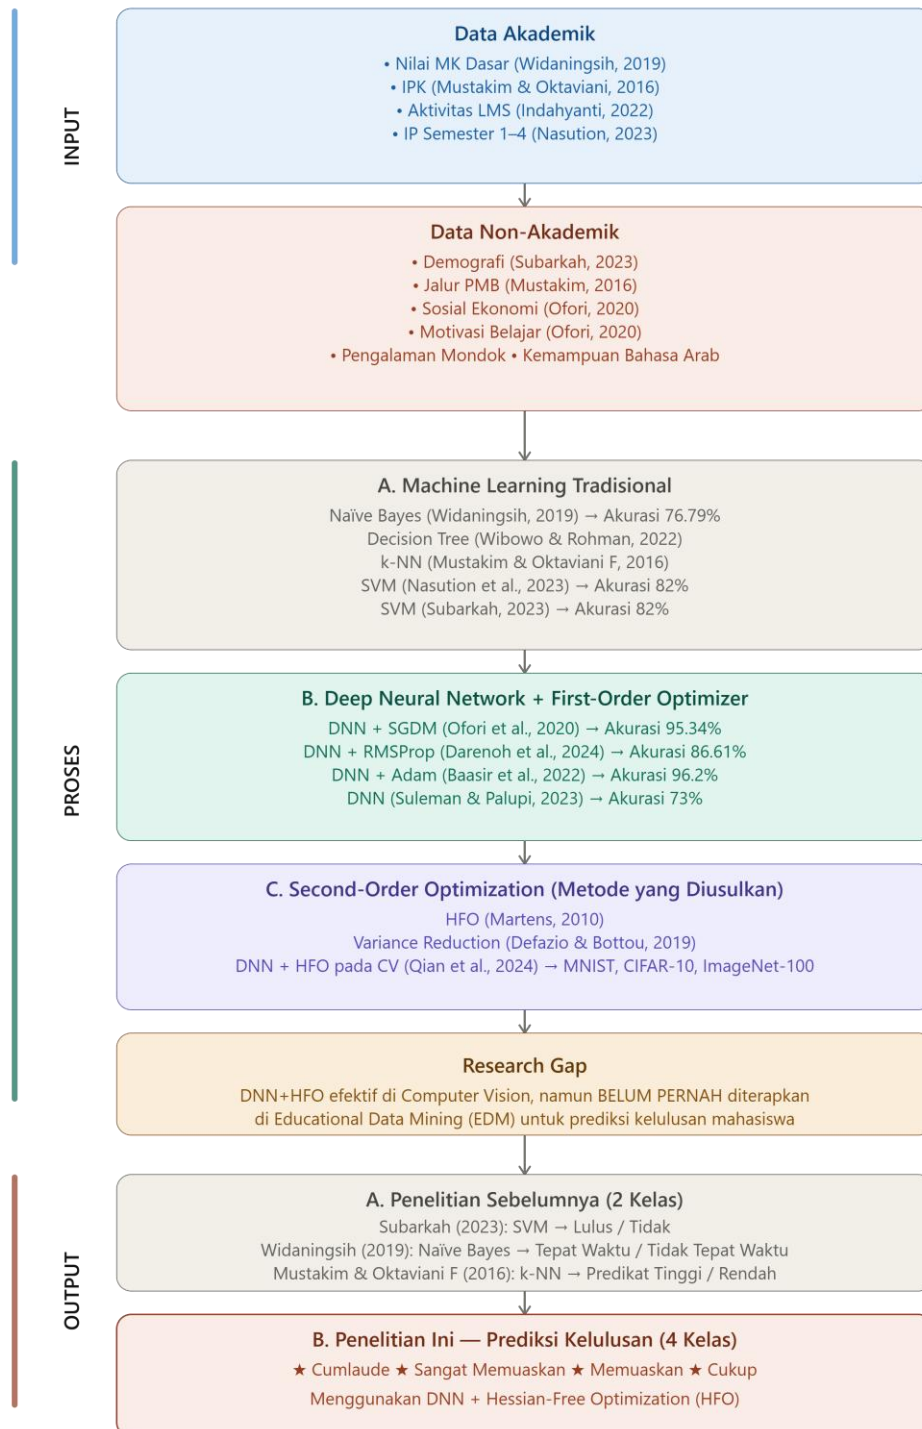
No	Peneliti & Tahun	Metode / Algoritma	Variabel / Data	Hasil Utama	Keterbatasan / Catatan
1	Subarkah (2023)	Naïve Bayes, SVM, Random Forest	IPS, jenis kelamin, demografi	SVM akurasi tertinggi 82%	Target hanya 2 kelas (lulus/tidak), belum memprediksi predikat
2	Widaningsih (2019)	Naïve Bayes, KNN, SVM, C4.5	Nilai akademik semester	Naïve Bayes akurasi 76,79%	Tidak mempertimbangkan faktor non-akademik
3	Khoiruddin (2018)	Analisis statistik (non-ML)	Tahfidzul Qur'an, motivasi belajar	Faktor religius & motivasi berpengaruh signifikan	Tidak menggunakan machine learning
4	Wibowo & Rohman (2022)	Naïve Bayes + Decision Tree	IPS semester 4 & 5	IPS 4–5 faktor dominan kelulusan	Variabel non-akademik tidak digunakan
5	Suleman & Palupi (2023)	Deep Neural Network (DNN)	Data multidimensi mahasiswa	DNN lebih akurat dari metode klasik	Optimisasi belum menggunakan metode lanjutan
6	Ofori dkk. (2020)	Neural Network + SGDM	Nilai akademik & sosial-ekonomi	Akurasi 95,34%	Optimizer SGDM lambat & rentan local minima
7	Katib & Ragab (2025)	VR-ODRNN + Coot Optimization	Dataset mahasiswa multivariabel	Akurasi 96,29%	Fokus pada seleksi fitur, bukan optimisasi DNN
8	Darenoh dkk. (2024)	DNN	Data akademik mahasiswa UB	Akurasi 86,61%	Optimizer first-order, rawan overfitting
9	Abdulkadirov dkk. (2023)	Review optimisasi NN	Studi literatur	Second-order lebih stabil & cepat	Bersifat ulasan, bukan implementasi
10	Qian dkk. (2024)	DNN + Hessian-Free Optimization	MNIST, CIFAR-10, ImageNet-100	Model lebih stabil & robust	Bukan domain pendidikan
11	Simanungkalit dkk. (2021)	ANN + MBGD vs LM	Data LMS pembelajaran daring	LM lebih akurat	Skala data terbatas
12	Ahmad dkk. (2021)	ANN + Levenberg–Marquardt	Nilai SPM & minat studi	Akurasi 93,2%	Fokus semester awal saja
13	Yaqin dkk. (2021)	ANN + Gradient Descent	IPK semester 1–4	Akurasi 77%	Optimisasi sederhana
14	Baashar dkk. (2022)	ANN + SGD vs Adam	Data Malaysia & Arab Saudi	Adam akurasi 96,2%	Belum mengeksplor optimisasi second-order

Dari analisis literatur di atas, terdapat beberapa gap yang perlu diisi dalam penelitian ini:

1. Konteks Unik Perguruan Tinggi Islam: Banyak penelitian sebelumnya mengabaikan faktor-faktor non-akademik yang khas untuk perguruan tinggi Islam, seperti pengalaman mondok, kemampuan berbahasa Arab, jalur seleksi berbasis keagamaan, dll. Penelitian ini berfokus untuk mengintegrasikan faktor akademik dan non-akademik, yang akan memberikan wawasan lebih komprehensif dalam prediksi predikat kelulusan mahasiswa di perguruan tinggi Islam.
2. Penggunaan Hessian-Free Optimization (HFO): Sejauh ini, tidak banyak penelitian yang menggunakan HFO untuk melatih DNN dalam konteks prediksi akademik. HFO berpotensi untuk meningkatkan efisiensi dan akurasi model DNN dengan mengatasi masalah konvergensi yang sering terjadi pada algoritma optimisasi tradisional.

2.3. Kerangka Teori

Kerangka teori dalam penelitian ini Gambar 2.1, disusun untuk memetakan posisi penelitian di antara penelitian-penelitian terdahulu dalam bidang prediksi kelulusan mahasiswa menggunakan Deep Neural Network (DNN) dan berbagai algoritma optimisasi. Kerangka teori ini terdiri dari tiga komponen utama, yaitu INPUT, PROSES dan OUTPUT, yang dijelaskan secara rinci sebagai berikut:



Gambar 2. 1 Kerangka Teori

1. Input

Input dalam penelitian ini terdiri dari dua kelompok variabel, yaitu data akademik dan data non-akademik.

a. Data Akademik

Data akademik merupakan variabel yang secara langsung berkaitan dengan capaian akademik mahasiswa selama menempuh pendidikan di perguruan tinggi. Berdasarkan kajian literatur, beberapa penelitian sebelumnya telah menggunakan berbagai indikator akademik sebagai prediktor kelulusan.

Widaningsih (2019) menggunakan nilai mata kuliah dasar sebagai indikator performa akademik mahasiswa dalam memprediksi nilai dan waktu kelulusan. Mustakim & Oktaviani F (2016) memanfaatkan Indeks Prestasi Kumulatif (IPK) sebagai salah satu faktor penentu dalam mengklasifikasikan predikat prestasi mahasiswa. Indahyanti et al. (2022) menambahkan aktivitas mahasiswa dalam sistem pembelajaran daring (LMS) sebagai variabel prediktor kinerja akademik. Nasution et al. (2023) menggunakan lama studi sebagai indikator keberhasilan akademik mahasiswa.

Penelitian ini menggunakan Indeks Prestasi Semester (IPS) semester 1 hingga 4 sebagai fitur utama, yang membedakannya dari penelitian-penelitian sebelumnya yang umumnya hanya menggunakan IPK atau nilai mata kuliah tertentu. IPS semester awal dipilih karena mencerminkan performa akademik mahasiswa pada fase awal masa studi dan memiliki korelasi kuat terhadap capaian akademik akhir.

b. Data Non-Akademik

Data non-akademik mencakup karakteristik demografi dan latar belakang mahasiswa yang berpotensi mempengaruhi capaian akademik. Subarkah (2023) menggunakan data demografi seperti jenis kelamin dan asal daerah dalam penelitiannya tentang prediksi kelulusan mahasiswa. Mustakim & Oktaviani F (2016) mempertimbangkan jalur penerimaan mahasiswa baru (PMB) sebagai salah satu faktor yang mempengaruhi keberhasilan studi. Ofori et al. (2020) memasukkan variabel sosial ekonomi dan motivasi belajar dalam model prediksi performa akademik mereka.

Penelitian ini memperluas cakupan data non-akademik dengan menambahkan variabel khas perguruan tinggi Islam, yaitu pengalaman mondok di pesantren dan kemampuan Bahasa Arab. Kedua variabel ini belum banyak dieksplorasi dalam penelitian-penelitian sebelumnya.

2. Proses/Metodologi

Proses dalam kerangka teori ini mengacu pada metode dan algoritma yang digunakan oleh peneliti-peneliti terdahulu dalam melakukan prediksi kelulusan mahasiswa. Berdasarkan kajian literatur, metode yang umum digunakan dapat dikelompokkan menjadi tiga kategori, yaitu Machine Learning Tradisional, Deep Neural Network dengan First-Order Optimizer, dan Second-Order Optimization.

a. Machine Learning Tradisional

Beberapa penelitian menggunakan algoritma *machine learning* tradisional sebagai pendekatan dasar dalam memprediksi kelulusan mahasiswa.

Widaningsih (2019) menerapkan algoritma Naïve Bayes dan berhasil mencapai akurasi sebesar 76,79%. Wibowo & Rohman (2022) menggunakan Decision Tree sebagai metode klasifikasi untuk memprediksi predikat kelulusan mahasiswa.

Mustakim & Oktaviani F (2016) mengimplementasikan k-Nearest Neighbor (k-NN) untuk mengelompokkan predikat prestasi mahasiswa. Nasution et al. (2023) menggunakan Support Vector Machine (SVM) dan memperoleh akurasi sebesar 82%. Subarkah (2023) menerapkan Random Forest dengan capaian akurasi 82%.

b. Deep Neural Network + First-Order Optimizer (Baseline)

Perkembangan *deep learning* mendorong penerapan Deep Neural Network (DNN) dalam prediksi akademik. Beberapa penelitian mengkombinasikan DNN dengan algoritma optimisasi turunan pertama (*first-order optimizer*).

Ofori et al. (2020) menggunakan DNN dengan Stochastic Gradient Descent with Momentum (SGDM) dan mencapai akurasi sebesar 95,34% dalam memprediksi performa akademik mahasiswa. Darenoh et al. (2024) mengimplementasikan DNN dengan RMSProp dan memperoleh akurasi sebesar 86,61%. Baashar et al. (2022) menggunakan DNN dengan Adam dan berhasil mencapai akurasi sebesar 96,2% pada dataset prediksi kelulusan. Suleman & Palupi (2023) menerapkan DNN tanpa optimizer khusus dan memperoleh akurasi sebesar 73%.

c. Second-Order Optimization

Berbeda dengan metode *first-order* yang hanya memanfaatkan informasi gradien, metode optimisasi turunan kedua (*second-order optimization*) memanfaatkan informasi kelengkungan (*curvature*) fungsi *loss* melalui matriks Hessian.

Martens (2010) memperkenalkan Hessian-Free Optimization (HFO) sebagai metode yang efisien untuk melatih *deep neural network* tanpa membentuk matriks Hessian secara eksplisit. Defazio & Bottou (2019) mengkaji efektivitas *variance reduction* dalam konteks *deep learning*. Qian et al. (2024) menerapkan DNN dengan

HFO pada bidang *computer vision* menggunakan dataset MNIST, CIFAR-10, dan ImageNet-100, dan menunjukkan hasil yang kompetitif.

Hingga saat ini, HFO belum diterapkan pada domain Educational Data Mining (EDM) untuk prediksi kelulusan mahasiswa.

3. Output

Output dalam kerangka teori ini menggambarkan hasil yang telah dicapai oleh penelitian-penelitian terdahulu serta target yang menjadi fokus penelitian ini. Penelitian-penelitian sebelumnya dalam bidang prediksi kelulusan mahasiswa pada umumnya masih terbatas pada klasifikasi biner (2 kelas). Artinya, model hanya memprediksi apakah mahasiswa akan lulus dengan predikat tertentu atau tidak, tanpa membedakan tingkatan predikat kelulusan secara lebih rinci.

Beberapa penelitian yang termasuk dalam kategori ini antara lain:

- Subarkah (2023) dengan metode SVM menghasilkan output 2 kelas, yaitu mahasiswa diprediksi Lulus atau Tidak Lulus.
- Widaningsih (2019) dengan metode Naïve Bayes menghasilkan output 2 kelas, yaitu mahasiswa diprediksi Tepat Waktu atau Tidak Tepat Waktu dalam menyelesaikan studi.
- Mustakim & Oktaviani F (2016) dengan metode k-NN menghasilkan output 2 kelas, yaitu mahasiswa diklasifikasikan ke dalam Predikat Tinggi atau Predikat Rendah.

Penelitian ini berfokus pada pengembangan model prediksi dengan target output yang berbeda dari penelitian-penelitian sebelumnya, yaitu Prediksi Predikat

Kelulusan Mahasiswa dalam 4 kelas (multiclass classification), yaitu: Cumlaude, Sangat Memuaskan, Memuaskan dan Cukup.

Keempat predikat ini sesuai dengan standar predikat kelulusan yang berlaku di Perguruan Tinggi di Indonesia pada umumnya, dan khususnya di Perguruan Tinggi Agama Islam.

Dengan demikian, penelitian ini akan mengimplementasikan:

1. DNN + HFO untuk klasifikasi predikat kelulusan mahasiswa.
2. Klasifikasi 4 kelas (Cumlaude, Sangat Memuaskan, Memuaskan, Cukup).
3. Variabel Non Akademik seperti variabel khas perguruan tinggi Islam sebagai fitur prediktor selain variabel akademik.

BAB III METODOLOGI PENELITIAN

3.1. Desain Penelitian

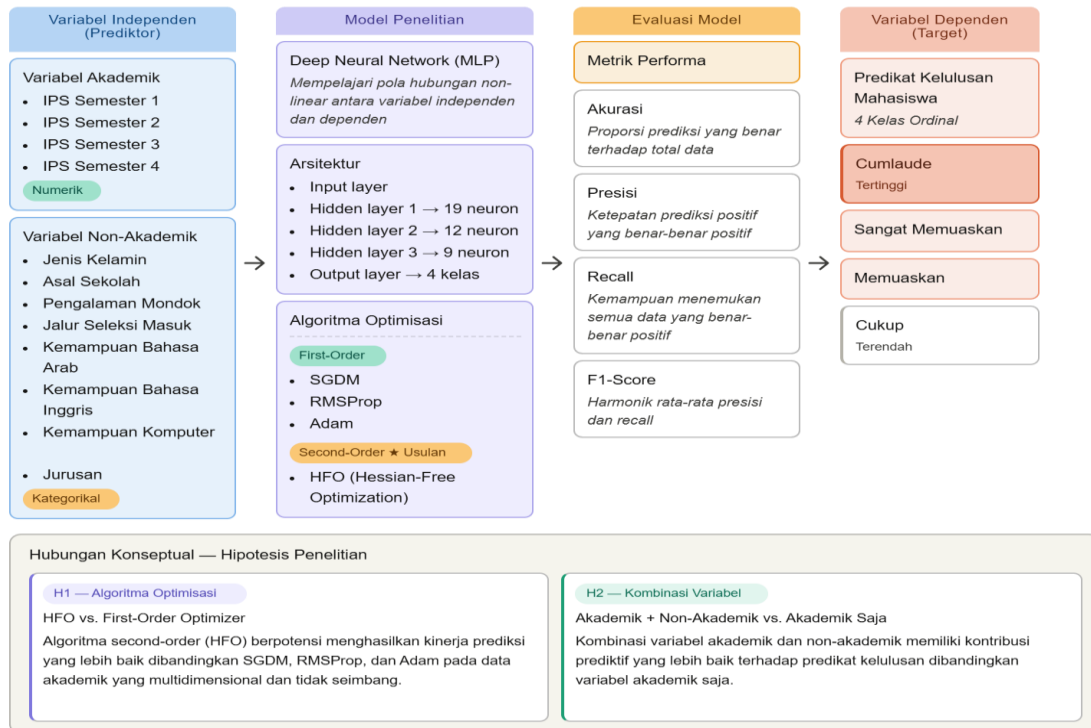
Penelitian ini menggunakan pendekatan kuantitatif berbasis *experimental design*. Secara spesifik, desain penelitian bersifat:

1. Eksperimental: Penelitian melibatkan pelatihan model *Deep Neural Network* (DNN) dengan berbagai algoritma optimisasi pada dataset yang terkontrol, sehingga peneliti dapat mengukur secara langsung pengaruh pemilihan *optimizer* terhadap kinerja model.
2. Komparatif: Penelitian membandingkan kinerja empat algoritma optimisasi, yaitu *Stochastic Gradient Descent with Momentum* (SGDM), *Root Mean Square Propagation* (RMSProp), *Adaptive Moment Estimation* (Adam), dan *Hessian-Free Optimization* (HFO) dalam tugas klasifikasi multikelas predikat kelulusan mahasiswa.
3. Studi Ablasi: Selain perbandingan *optimizer*, penelitian juga melakukan studi ablasi fitur untuk mengevaluasi kontribusi relatif variabel akademik dan non-akademik terhadap kinerja model prediksi.

Dengan desain ini, penelitian dapat menguji dua pernyataan utama: (1) HFO sebagai *optimizer second-order* berpotensi menghasilkan performa yang lebih baik dibandingkan *optimizer first-order* konvensional, dan (2) kontribusi variabel non-akademik terhadap prediksi predikat kelulusan.

3.2. Kerangka Konsep

Kerangka konsep menjelaskan hubungan antar variabel secara konseptual, tanpa menjelaskan langkah teknis implementasi.



Gambar 3. 1 Kerangka Konsep

Kerangka konsep ini menyusun langkah-langkah dan komponen yang digunakan dalam pemodelan serta bagaimana setiap elemen berinteraksi untuk mencapai tujuan penelitian. Berikut adalah penjelasan komponen utama dalam kerangka konsep penelitian ini:

1. Variabel Independen (Prediktor)

Penelitian ini menggunakan dua jenis variabel utama, yaitu:

- Variabel Akademik: Variabel ini mencakup data yang berhubungan langsung dengan performa akademik mahasiswa yaitu Indeks Prestasi Semester (IPS) semester 1 sampai dengan 4.
- Variabel Non-Akademik: Variabel ini mencakup informasi yang lebih bersifat pribadi dan lingkungan mahasiswa, seperti jenis kelamin, asal sekolah, pengalaman mondok di pesantren, kemampuan bahasa (Arab dan Inggris), kemampuan komputer, jalur seleksi masuk, dan jurusan yang diambil.

2. Model Penelitian

Variabel independen diproses melalui model Deep Neural Network (DNN) dengan arsitektur Multilayer Perceptron (MLP) yang terdiri dari tiga *hidden layer* (19, 12, dan 9 neuron). Model dilatih menggunakan empat algoritma optimisasi SGDM, RMSProp, Adam dan HFO (Hessian-Free Optimization).

Model DNN bertugas mempelajari pola hubungan non-linear antara variabel independen dan variabel dependen.

3. Evaluasi Model

Evaluasi model dilakukan dengan menggunakan metrik performa, yaitu:

- Akurasi: Mengukur seberapa banyak prediksi yang benar dibandingkan dengan total data.
- Presisi: Mengukur sejauh mana hasil prediksi yang positif benar-benar positif.
- Recall: Mengukur sejauh mana prediksi yang positif berhasil menemukan semua hasil yang benar-benar positif.

- F1-Score: Metrik yang menggabungkan presisi dan recall dalam satu angka yang memberikan gambaran keseluruhan kinerja model.

4. Variabel Dependen (Target)

Variabel dependen adalah predikat kelulusan mahasiswa yang terdiri dari empat kelas ordinal: Cumlaude (tertinggi), Sangat Memuaskan, Memuaskan dan Cukup (terendah).

5. Hubungan Konseptual

Secara konseptual, penelitian ini menguji dua hipotesis utama:

- Algoritma optimisasi *second-order* (HFO) berpotensi menghasilkan kinerja prediksi yang lebih baik dibandingkan algoritma *first-order* (SGDM, RMSProp, Adam) dalam konteks data akademik yang multidimensional dan tidak seimbang.
- Kombinasi variabel akademik dan non-akademik memiliki kontribusi prediktif yang lebih baik terhadap predikat kelulusan dibandingkan variabel akademik.

3.3. Kerangka Penelitian


Kerangka penelitian ini terdiri dari beberapa tahapan sistematis, seperti tergambar dalam diagram Gambar 3.2.

Penjelasan Tahapan Sistematis Kerangka Penelitian

1. Studi Literatur

Penelitian diawali dengan studi literatur untuk memperoleh pemahaman mendalam terkait metode Deep Neural Network (DNN), khususnya arsitektur Multilayer Perceptron (MLP), serta algoritma optimisasi seperti Hessian-Free Optimization (HFO), Stochastic Gradient Descent with Momentum (SGDM),

Root Mean Square Propagation (RMSProp), dan Adaptive Moment Estimation (Adam). Kajian ini mencakup teori dasar, penelitian terdahulu, serta perkembangan teknologi machine learning dan Educational Data Mining (EDM) yang relevan dengan prediksi predikat kelulusan mahasiswa.



Gambar 3. 2 Kerangka Penelitian

2. Pengumpulan Data Akademik dan Non-Akademik

Data penelitian dikumpulkan dari data historis alumni Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang angkatan 2009–2021. Data terdiri dari variabel akademik, yaitu IPS Semester 1 sampai Semester 4, serta variabel non-akademik yang meliputi jenis kelamin, asal sekolah, pengalaman mondok di pesantren, jalur penerimaan mahasiswa baru, kemampuan Bahasa Arab, kemampuan Bahasa Inggris, kemampuan komputer, dan jurusan. Tahapan ini bertujuan membangun dataset yang komprehensif untuk proses pelatihan model prediksi.

3. Pra-pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk memastikan kualitas dan konsistensi data sebelum digunakan dalam pelatihan model. Proses diawali dengan seleksi fitur dan penentuan variabel target yaitu predikat kelulusan mahasiswa. Nilai kosong pada data kategorikal diimputasi menggunakan modus, sedangkan data numerik diimputasi menggunakan median. Selanjutnya dataset dibagi menjadi data latih, validasi, dan data uji dengan proporsi 60:20:20 menggunakan stratified split untuk menjaga keseimbangan distribusi kelas. Variabel kategorikal ditransformasikan menggunakan One-Hot Encoding, sedangkan variabel numerik dinormalisasi menggunakan StandardScaler. Seluruh transformasi dilakukan menggunakan ColumnTransformer untuk menghasilkan representasi numerik yang siap digunakan pada model DNN.

4. Analisis Kontribusi Variabel

Tahap ini bertujuan memberikan gambaran awal mengenai hubungan antar variabel prediktor terhadap target predikat kelulusan mahasiswa. Analisis dilakukan menggunakan Pearson Correlation untuk mengidentifikasi kekuatan hubungan linear antara variabel akademik maupun non-akademik terhadap variabel target.

5. Pemodelan DNN dan Pelatihan Optimizer

Pada tahap ini dibangun model Deep Neural Network berbasis Multilayer Perceptron (MLP) dengan tiga hidden layer. Model dilatih menggunakan beberapa algoritma optimisasi, yaitu SGDM, RMSProp, Adam, dan Hessian-Free Optimization (HFO). Optimizer first-order digunakan sebagai baseline, sedangkan HFO digunakan sebagai pendekatan second-order yang memanfaatkan informasi kurvatur loss melalui Hessian-Vector Product tanpa membentuk matriks Hessian secara eksplisit.

6. Perbandingan Performa Optimizer

Tahap ini bertujuan membandingkan performa masing-masing optimizer dalam melatih model DNN pada tugas klasifikasi predikat kelulusan mahasiswa. Perbandingan dilakukan menggunakan arsitektur model, dataset, dan parameter pelatihan yang setara sehingga hasil evaluasi dapat dibandingkan secara adil dan objektif.

7. Evaluasi Performa Model

Setiap model dievaluasi menggunakan beberapa metrik klasifikasi multikelas, yaitu accuracy, precision, recall, dan F1-score. Selain itu, confusion matrix digunakan untuk menganalisis pola kesalahan klasifikasi antar kelas predikat

kelulusan mahasiswa. Hasil evaluasi digunakan untuk menentukan optimizer dengan performa terbaik.

8. Studi Ablasi Fitur

Studi ablasi dilakukan untuk mengukur kontribusi tambahan variabel non-akademik terhadap performa model prediksi. Pada tahap ini dibandingkan dua skenario model, yaitu Model A yang menggunakan fitur akademik dan non-akademik, serta Model B yang hanya menggunakan fitur akademik. Kedua model dilatih menggunakan optimizer terbaik hasil tahap sebelumnya, yaitu HFO.

9. Interpretasi Hasil dan Penarikan Kesimpulan

Tahap terakhir dilakukan interpretasi terhadap seluruh hasil eksperimen untuk menganalisis performa masing-masing optimizer dan kontribusi variabel terhadap prediksi predikat kelulusan mahasiswa. Tahap ini juga mencakup pembahasan implikasi penelitian dalam bidang Educational Data Mining dan pengembangan sistem prediksi akademik di perguruan tinggi, serta penarikan kesimpulan dan rekomendasi untuk penelitian selanjutnya.

3.4. Sumber Data dan Variabel Penelitian

1. Sumber Data: Data yang digunakan dalam penelitian ini merupakan data historis alumni Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang angkatan tahun 2009–2021. Data diperoleh melalui sistem informasi akademik (SIKAD) fakultas dengan persetujuan pihak terkait. Secara keseluruhan, data mentah terdiri dari 6.929 baris observasi mahasiswa.

2. Variabel Penelitian

a. Variabel Prediktor (Fitur)

Variabel prediktor terbagi menjadi dua kelompok:

1. Variabel Akademik (numerik kontinu):

- IPS Semester 1
- IPS Semester 2
- IPS Semester 3
- IPS Semester 4

2. Variabel Non-Akademik (kategorikal nominal):

- Jenis kelamin (Laki-laki, Perempuan)
- Jenis asal sekolah (Madrasah, Sekolah Umum)
- Pengalaman mondok di pesantren (Ya, Tidak)
- Jalur penerimaan mahasiswa baru (Beasiswa, Mandiri, Seleksi Nasional, Seleksi PTKIN, Transfer)
- Kemampuan Bahasa Arab (Tidak Bisa, Pasif, Aktif, Mahir)
- Kemampuan Bahasa Inggris (Tidak Bisa, Pasif, Aktif, Mahir)
- Kemampuan Komputer (Tidak Bisa, Operator, Programmer)
- Jurusan (Matematika, Biologi, Kimia, Fisika, Teknik Informatika, Teknik Arsitektur, Perpustakaan dan Sains Informasi)

Data yang terdiri dari campuran variabel numerik dan kategorikal disebut sebagai *mixed data* atau *heterogeneous data*. Jenis data ini sangat umum ditemukan dalam berbagai domain, termasuk kesehatan, keuangan, pemasaran, dan pendidikan. Penggunaan kedua tipe variabel secara bersama dalam model

prediksi merupakan praktik standar dalam *machine learning*, bukan sesuatu yang luar biasa. Potdar *et al.* (2017) menyatakan bahwa dalam analisis klasifikasi, variabel dependen sering dipengaruhi tidak hanya oleh variabel berskala rasio (numerik), tetapi juga oleh variabel kualitatif (kategorikal). Karena algoritma *machine learning* hanya menerima input numerik, maka variabel kategorikal harus di-*encode* terlebih dahulu. Tantangan utamanya adalah bahwa model *deep learning* tidak dapat bekerja langsung pada data kategorikal dalam bentuk aslinya. Solusi bakunya adalah mentransformasikan variabel kategorikal ke dalam representasi numerik terlebih dahulu, kemudian menggabungkannya dengan variabel numerik menjadi satu vektor input tunggal.

Metode standar untuk mentransformasikan variabel kategorikal nominal adalah *One-Hot Encoding*. Metode ini dipilih karena mampu mempertahankan independensi antar kategori dan tidak menimbulkan hubungan ordinal semu yang dapat membingungkan model. Potdar *et al.* (2017) membandingkan tujuh teknik *encoding* untuk *neural network classifiers* dan menunjukkan bahwa pemilihan teknik *encoding* yang tepat berpengaruh signifikan terhadap akurasi klasifikasi. Selain itu, Delong & Kozak (2023) secara eksplisit menyatakan bahwa representasi numerik dari fitur kategorikal digabungkan dengan fitur numerik dan dimasukkan bersama sebagai input ke dalam *hidden layer* jaringan saraf. Setelah melalui *One-Hot Encoding*, variabel kategorikal berubah menjadi vektor biner yang bersifat numerik. Vektor biner ini kemudian

digabungkan (*concatenated*) secara horizontal dengan variabel numerik (IPS 1–4 yang telah di-*scale*) menjadi satu vektor fitur berdimensi 33.

Selain justifikasi teoretis, terdapat bukti empiris bahwa model yang menggunakan *mixed data* menghasilkan performa yang baik. Kraus & Feuerriegel (2017) dalam penelitiannya menggunakan *deep neural networks* untuk prediksi pasar keuangan yang menggabungkan berbagai tipe data. Delong & Kozak (2023) juga mendemonstrasikan bahwa penggunaan *joint embedding* untuk semua fitur kategorikal yang digabungkan dengan fitur numerik menghasilkan peningkatan *predictive power* yang signifikan pada dataset nyata. Dengan demikian, penggunaan IPS 1–4 (numerik) bersama dengan delapan variabel non-akademik (kategorikal) dalam penelitian ini dapat diterapkan dalam praktik standar *deep learning*. Kombinasi kedua tipe variabel ini justru memperkaya representasi data dan berpotensi meningkatkan akurasi prediksi, sebagaimana dibuktikan dalam studi ablasi fitur penelitian ini.

b. Variabel Target (Label)

Variabel target adalah predikat kelulusan mahasiswa yang terdiri dari empat kelas ordinal yang dipetakan dalam Tabel 3.1.

Tabel 3. 1 Pemetaan Label Target ke Kode Numerik dan One-Hot Encoding

Predikat	Kode Numerik	Kode One-Hot
Cukup	0	[1, 0, 0, 0]
Memuaskan	1	[0, 1, 0, 0]
Sangat Memuaskan	2	[0, 0, 1, 0]
Cumlaude	3	[0, 0, 0, 1]

3.5. Tahapan Pra-pemrosesan Data

Seluruh tahapan pra-pemrosesan data dirancang untuk menghindari *data leakage*. Artinya, parameter imputasi, *encoding*, dan *scaling* hanya dihitung dari data latih, kemudian diterapkan ke data validasi dan data uji.

1. Pembersihan dan Imputasi Data

Langkah-langkah pembersihan data:

- Simbol "-" pada data mentah dikonversi menjadi nilai NaN (*Not a Number*).
- Pada variabel kategorikal, nilai kosong diimputasi menggunakan modus (nilai paling sering muncul) yang dihitung dari data latih.
- Pada variabel numerik (IPS 1–4), nilai kosong dikonversi ke tipe numerik terlebih dahulu, kemudian diimputasi menggunakan median yang dihitung dari data latih.

Pendekatan imputasi ini dipilih untuk menjaga stabilitas distribusi data serta menghindari pengurangan jumlah observasi akibat penghapusan baris.

2. Pembagian Dataset

Tabel 3. 2 Pembagian Dataset

Subset	Proporsi	Jumlah Data
Data Latih (<i>Training</i>)	60%	4.157
Data Validasi (<i>Validation</i>)	20%	1.386
Data Uji (<i>Testing</i>)	20%	1.386
Total	100%	6.929

Pembagian dilakukan secara bertahap:

- Seluruh dataset dibagi menjadi 80% data latih sementara dan 20% data uji.

- Data latih sementara (80%) dibagi menjadi 75% data latih dan 25% data validasi, sehingga menghasilkan proporsi akhir 60:20:20.

3. Encoding dan Scaling

a. Encoding Variabel Kategorikal

Seluruh variabel kategorikal dalam penelitian ini diperlakukan sebagai kategorikal nominal, yaitu variabel yang tidak memiliki urutan atau tingkatan nilai (seperti jenis kelamin, jurusan, dan jalur PMB). Karena model *Deep Neural Network* (DNN) hanya dapat memproses data dalam bentuk numerik (Goodfellow *et al.*, 2016), variabel kategorikal harus ditransformasikan terlebih dahulu.

Transformasi dilakukan menggunakan teknik One-Hot Encoding. Teknik ini mengubah setiap kategori unik dari suatu variabel menjadi sebuah vektor biner dengan panjang sejumlah kategori, di mana hanya satu elemen yang bernilai 1 (*hot*) dan sisanya bernilai 0 (Guntara & Astuti, 2025). Sebagai contoh, variabel *Jenis Kelamin* dengan dua kategori (Laki-laki dan Perempuan) akan diubah menjadi dua kolom biner terpisah: *Jenis Kelamin_Laki-laki* dan *Jenis Kelamin_Pemempuan*.

Pemilihan One-Hot Encoding didasarkan pada beberapa pertimbangan:

1. Menghindari Hubungan Ordinal Semu: Jika digunakan *Label Encoding* (memberi angka 0, 1, 2, ... secara berurutan), model akan salah mengartikan bahwa terdapat urutan atau tingkatan antar kategori (misalnya: *Teknik Informatika* > *Biologi*) yang sebenarnya tidak ada (Guntara & Astuti, 2025). Hal ini karena label encoding menghasilkan nilai numerik

yang bersifat kuantitatif (1, 2, 3, ...) yang dapat diinterpretasikan model sebagai hubungan ordinal, padahal variabel nominal tidak memiliki hierarki. Sebaliknya, One-Hot Encoding merepresentasikan setiap kategori secara setara dalam bentuk biner 0 dan 1, sehingga tidak menimbulkan bias ordinal (Potdar *et al.*, 2017).

2. Kompatibilitas dengan DNN: Penelitian yang dilakukan oleh Potdar, Pardawala, dan Pai (2017) membandingkan berbagai teknik encoding untuk *neural network classifiers* dan menunjukkan bahwa One-Hot Encoding merupakan pilihan yang tepat untuk model berbasis jaringan saraf tiruan karena mampu mempertahankan independensi antar kategori.
3. Pencegahan *Data Leakage*: Proses *fitting* encoder (menentukan pemetaan kategori ke vektor biner) memastikan bahwa informasi dari data uji tidak "bocor" ke proses pelatihan.

Penerapan *one-hot encoding* pada delapan variabel kategorikal dalam penelitian ini menghasilkan peningkatan dimensi fitur input secara signifikan, yaitu:

- Jenis Kelamin dengan 2 kategori : 2 fitur biner
- Jenis Sekolah dengan 2 kategori : 2 fitur biner
- Pengalaman Mondok dengan 2 kategori : 2 fitur biner
- Jalur PMB dengan 5 kategori : 5 fitur biner
- Kemampuan Bahasa Arab dengan 4 kategori : 4 fitur biner
- Kemampuan Bahasa Inggris dengan 4 kategori : 4 fitur biner
- Kemampuan Komputer dengan 3 kategori : 3 fitur biner

- Jurusan dengan 7 kategori : 7 fitur biner.

Secara keseluruhan, kedelapan variabel kategorikal tersebut menghasilkan 29 fitur biner setelah melalui proses *one-hot encoding*. Sementara itu, keempat variabel numerik (IPS 1, IPS 2, IPS 3, dan IPS 4) tetap sebagai 4 fitur numerik yang akan dinormalisasi menggunakan *StandardScaler*. Dengan demikian, total dimensi input yang masuk ke dalam model Deep Neural Network (DNN) adalah **33 neuron** pada *input layer*, yang merupakan gabungan dari 29 fitur biner hasil *one-hot encoding* dan 4 fitur numerik IPS 1–4 yang telah dinormalisasi.

b. Scaling Variabel Numerik

Variabel numerik (IPS 1–4) dinormalisasi menggunakan *StandardScaler* (Z-Score Normalization):

$$z_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \dots\dots\dots (III.1)$$

dengan μ_j dan σ_j adalah rata-rata dan standar deviasi fitur j yang dihitung dari data latih.

Normalisasi dilakukan untuk menyamakan skala antar fitur, mempercepat konvergensi pelatihan DNN, dan menghindari dominasi fitur dengan skala numerik yang lebih besar. Fitur hasil *one-hot encoding* tidak dilakukan *scaling* karena telah berada pada rentang nilai 0 dan 1.


Seluruh proses *encoding* dan *scaling* diintegrasikan menggunakan *ColumnTransformer* dari *scikit-learn* untuk memastikan transformasi yang konsisten pada data latih, validasi, dan uji.

3.6. Desain Arsitektur Model

Model yang digunakan dalam penelitian ini adalah Multilayer Perceptron (MLP) feedforward dengan arsitektur sebagai berikut:

Tabel 3. 3 Arsitektur Multilayer Perceptron (MLP)

Lapisan	Jumlah Neuron	Fungsi Aktivasi
Input	33 (setelah one-hot encoding)	-
Hidden Layer 1	19	ReLU
Hidden Layer 2	12	ReLU
Hidden Layer 3	9	ReLU
Output	4	Softmax



Gambar 3. 3 Desain Arsitektur Model MLP feedforward

Model yang digunakan dalam penelitian ini merupakan jenis Multi-Layer Perceptron (MLP) feedforward, yang terdiri dari tiga komponen utama yaitu: lapisan input, *hidden layers*, dan lapisan output. Gambar 3.3 menunjukkan arsitektur model DNN yang dirancang dalam penelitian ini.

1. Lapisan Input

Lapisan input terdiri dari 33 neuron yang memrepresentasikan 12 fitur dari dataset (yang setelah dilakukan praprosesing one-hot-encoding pada data kategorikal sehingga pada model desain arsitektur menjadi 33 neuron input). Setiap neuron menerima satu nilai input x_i yang akan diproses secara paralel menuju ke lapisan tersembunyi pertama. Input ini dapat berupa fitur numerik atau hasil pra-pemrosesan data yang relevan dengan prediksi target.

2. *Hidden Layers*

Dalam penelitian ini, digunakan arsitektur Multilayer Perceptron (MLP) dengan tiga buah *hidden layer* sebagai model jaringan saraf tiruan. Meskipun secara terminologi, MLP dapat digunakan untuk menyebut jaringan saraf dengan satu atau lebih *hidden layer*, namun ketika arsitektur memiliki lebih dari satu *hidden layer*, maka jaringan tersebut sudah dapat dikategorikan sebagai Deep Neural Network (DNN).

Penggunaan tiga *hidden layer* dalam penelitian ini bertujuan untuk memberikan kemampuan representasi yang lebih tinggi dibandingkan dengan jaringan yang hanya memiliki satu *hidden layer*. Dengan adanya beberapa lapisan tersembunyi, model memiliki kapasitas untuk menangkap hubungan non-linear yang lebih kompleks di antara fitur-fitur input dan target output.

Klasifikasi sebagai DNN merujuk pada definisi umum dalam bidang deep learning, dimana jaringan dikatakan “deep” apabila memiliki lebih dari satu *hidden layer* (Goodfellow and Yoshua Bengio, 2016). Struktur deep ini memungkinkan model untuk belajar representasi bertingkat (*hierarchical representation*) dari data, sehingga meningkatkan potensi performa prediksi, terutama pada kasus klasifikasi multikelas seperti pada penelitian ini. *Hidden Layer* Pertama terdiri dari 19 neuron, *hidden layer* kedua terdiri dari 12 neuron, dan *Hidden Layer* Ketiga terdiri dari 9 neuron dengan masing-masing fungsi aktivasinya menggunakan ReLU (*Rectified Linear Unit*). Pemilihan fungsi aktivasi ReLU pada *hidden layer* didasarkan pada keunggulannya dalam mengatasi masalah *vanishing gradient* yang umum terjadi pada fungsi aktivasi klasik seperti sigmoid dan tanh, karena ReLU memiliki turunan konstan (1) untuk nilai positif sehingga gradien tetap mengalir dengan stabil pada proses backpropagation. Selain itu, ReLU menghasilkan aktivasi yang jarang (*sparse*), mempercepat konvergensi, serta lebih efisien secara komputasi. Karakteristik ReLU yang bersifat *piecewise linear* (potongan garis lurus) juga membuat perhitungan *Hessian-vector product* pada optimasi tingkat dua seperti Hessian-Free Optimization (HFO) lebih stabil dibandingkan fungsi non-linear lain yang kompleks, sehingga cocok digunakan dalam DNN (Yann Lecun, Yoshua Bengio, 2016).

Pemilihan jumlah neuron pada *hidden layer* mengacu pada pendekatan heuristik umum dalam desain jaringan saraf, jumlah neuron *hidden layer* sering kali dipilih dengan formulasi rumus III.2, sebagai berikut:

$$\Sigma_{\text{neuron}} = \frac{\Sigma_{\text{input}} + \Sigma_{\text{output}}}{2} \dots\dots\dots\text{(III.2)}$$

Oleh karena itu, pemilihan 19, 12 dan 9 merupakan bentuk eksplorasi dari arsitektur yang wajar dan tidak terlalu dangkal maupun terlalu dalam.

Transformasi pada tiap layer mengikuti formulasi umum sebagaimana rumus III.3 dan III.4:

$$z^{(l)} = w^{(l)} a^{(l-1)} + b \dots\dots\dots (III.3)$$

$$a^{(l)} = f^{(l)}(z^{(l)}) \dots\dots\dots (III.4)$$

dimana:

- $z^{(l)}$ adalah nilai input sebelum aktivasi pada layer ke- l ,
- $a^{(l-1)}$ adalah output dari layer sebelumnya,
- $w^{(l)}$ adalah bobot koneksi,
- b adalah bias,
- $f^{(l)}$ adalah fungsi aktivasi (dalam hal ini ReLU).

3. Lapisan Output

Pada arsitektur jaringan saraf tiruan Multilayer Perceptron (MLP) yang digunakan dalam penelitian ini, jumlah neuron pada lapisan output disesuaikan dengan jumlah kelas target, yaitu sebanyak empat kelas. Oleh karena itu, lapisan output dirancang dengan empat neuron, masing-masing mewakili satu kelas yang mungkin diprediksi oleh model.

Fungsi aktivasi yang digunakan pada lapisan output adalah *softmax*, yang bertugas mengubah output neuron menjadi nilai probabilitas terstandarisasi. Probabilitas tertinggi yang dihasilkan dari keempat neuron tersebut dipilih sebagai hasil prediksi akhir, melalui proses *argmax* sebagaimana rumus II.3.

Sesuai dengan panduan umum dalam klasifikasi multikelas, jumlah neuron pada output layer harus sama dengan jumlah kelas target, dan *softmax* digunakan untuk

menghasilkan distribusi probabilitas antar kelas (Geron, 2019). Pendekatan ini memungkinkan model untuk membandingkan semua kelas sekaligus dan menentukan satu kelas terbaik berdasarkan probabilitas tertinggi.

Fungsi aktivasi yang digunakan adalah *Softmax* sebagaimana rumus III.5, yang mengubah output menjadi probabilitas prediksi untuk setiap kelas:

$$\text{softmax}(\mathbf{z}^{(L)})_k = \frac{e^{z_k}}{\sum_{j=1}^K e^{z_j}}, \quad k = 1, 2, \dots, K \quad \text{.....(III.5)}$$

4. Fungsi Loss

Model menggunakan fungsi loss *cross-entropy* yang diformulasikan dalam rumus III.6:

$$\text{Loss} = - \sum_{k=1}^K y_k \log(\hat{y}_k) \quad \text{.....(III.6)}$$

untuk mengukur perbedaan antara prediksi dan label target sebenarnya. Fungsi ini cocok untuk tugas klasifikasi multi-kelas.

3.7. Algoritma Optimisasi

Optimisasi dalam DNN bertujuan untuk meminimalkan fungsi *loss* $\mathcal{L}(\theta)$ selama pelatihan. Pembaruan parameter secara umum mengikuti rumus:

$$\theta_{t+1} = \theta_t - \eta \nabla \mathcal{L}(\theta_t) \quad \text{.....(III.7)}$$

dengan θ_t adalah parameter pada iterasi ke- t , η adalah *learning rate*, dan $\nabla \mathcal{L}(\theta_t)$ adalah gradien fungsi *loss*.

1. First-Order Optimizers (SGDM, RMSProp, Adam)

Tiga algoritma optimisasi *first-order* digunakan sebagai *baseline*:

- a. Stochastic Gradient Descent with Momentum (SGDM)

SGDM menambahkan "memori" dari arah pergerakan sebelumnya untuk mengurangi osilasi dan mempercepat konvergensi.

b. Root Mean Square Propagation (RMSProp)

RMSProp menggunakan rata-rata bergerak dari kuadrat gradien untuk menstabilkan *learning rate*.

c. Adaptive Moment Estimation (Adam)

Adam menggabungkan kelebihan RMSProp dan momentum dengan memperhitungkan momen pertama dan kedua dari gradien.

Ketiga *optimizer* ini diimplementasikan menggunakan library TensorFlow/Keras standar, tanpa modifikasi manual. Hal ini dilakukan karena implementasi bawaan TensorFlow/Keras sudah teruji dan optimal secara komputasi, dan menggunakan *library* standar memastikan hasil yang diperoleh dapat direplikasi dengan mudah oleh peneliti lain.

Parameter pelatihan untuk ketiga *optimizer*: *Learning rate* (η) 0,001, ukuran *batch* 32 dan jumlah *epoch* sampai dengan konvergen (*EarlyStopping*).

2. *Hessian-Free Optimization* (HFO)

Berbeda dengan ketiga *baseline* di atas, HFO tidak tersedia sebagai *optimizer* bawaan dalam TensorFlow/Keras. Oleh karena itu, HFO diimplementasikan secara semi-manual dengan rincian sebagai berikut:

- Gradien dan fungsi loss tetap dihitung menggunakan *automatic differentiation* TensorFlow.

- Hessian-vector product (HVP) dihitung menggunakan operasi gradien kedua (*nested gradient*) yang disediakan TensorFlow.
- Iterasi Conjugate Gradient (CG) diimplementasikan secara manual menggunakan operasi vektor.
- Line search Armijo dan adaptasi damping diimplementasikan secara manual.

Berikut adalah penjelasan setiap komponen implementasi HFO yang digunakan dalam penelitian ini.

a. Manajemen Parameter (Vektorisasi)

Parameter model DNN (bobot dan bias) disimpan dalam bentuk tensor dengan berbagai dimensi. Namun, algoritma Conjugate Gradient (CG) bekerja pada ruang vektor Euclidean satu dimensi. Oleh karena itu, sebelum memulai pelatihan HFO, semua parameter di-flatten menjadi satu vektor panjang. Proses ini meliputi:

- Flatten: Menggabungkan semua parameter menjadi satu vektor 1D.
- Split: Memecah vektor kembali menjadi bagian-bagian sesuai ukuran asli setiap parameter.
- Reshape: Mengubah setiap bagian kembali ke bentuk tensor asli.
- Add step: Menambahkan vektor langkah ke parameter model.

Pendekatan ini diperlukan karena CG hanya dapat beroperasi pada vektor 1D, sementara model DNN menyimpan parameter dalam bentuk tensor multidimensi.

b. Hessian-Vector Product (HVP)

HVP adalah komponen kunci dalam HFO. Matriks Hessian tidak pernah dibentuk secara eksplisit; yang dihitung adalah hasil kali antara matriks Hessian dengan suatu vektor. Implementasi ini mengikuti identitas Pearlmutter (1994):

$$H(\theta)v = \nabla_{\theta}(g(\theta)^{\top}v) \dots\dots\dots(\text{III.8})$$

Langkah-langkah perhitungan HVP adalah sebagai berikut:

1. Vektor input v di-reshape kembali ke bentuk tensor agar sesuai dengan struktur parameter model.
2. Gradien $g = \nabla\mathcal{L}(\theta)$ dihitung menggunakan `tf.GradientTape` pertama.
3. Hasil kali titik (dot product) $g^{\top}v$ dihitung.
4. Gradien dari $g^{\top}v$ terhadap parameter dihitung menggunakan `tf.GradientTape` kedua, yang menghasilkan Hv .
5. Efek damping (λv) ditambahkan sehingga menghasilkan $(H + \lambda I)v$.

c. Conjugate Gradient (CG)

CG adalah algoritma iteratif untuk menyelesaikan sistem linear $Ad = b$ di mana A simetris dan *positive definite*. Dalam HFO, sistem yang diselesaikan adalah:

$$(H + \lambda I)d = -g$$

Algoritma CG diimplementasikan dengan langkah-langkah sebagai berikut:

1. Tentukan residual awal

$$r_0 = -\nabla\mathcal{L}(\theta) - H(\theta)v_0 \dots\dots\dots(\text{III.9})$$

- r_0 : vektor residual awal (selisih antara gradien aktual dan aproksimasi).
- $\nabla\mathcal{L}(\theta)$: gradien fungsi *Loss* terhadap parameter θ .
- $H(\theta)$: matriks Hessian fungsi *Loss* (turunan kedua).
- v_0 : taksiran solusi awal (biasanya vektor nol atau inisialisasi lain).

2. Hitung arah pencarian awal

$p_0 = r_0$

p_0 : arah pencarian awal dalam ruang solusi.

3. Untuk iterasi $i = 0, 1, 2, \dots$:

- Hitung:

$$\alpha_i = \frac{r_i^T r_i}{p_i^T H(\theta) p_i} \dots\dots\dots (III.10)$$

α_i : panjang langkah (step size) pada arah pencarian p_i .
 $r_i^T r_i$: hasil kali dalam (dot product) residual dengan dirinya (kuadrat norma).
 $p_i^T H(\theta) p_i$: kuadrat norma arah pencarian dalam ruang Hessian.

- Update vektor pencarian:

$$v_{i+1} = v_i + \alpha_i p_i \dots\dots\dots (III.11)$$

v_{i+1} : estimasi solusi baru pada iterasi ke- $i + 1$.

- Hitung residual baru:

$$r_{i+1} = r_i - \alpha_i H(\theta) p_i \dots\dots\dots (III.12)$$

r_{i+1} : residual pada iterasi ke- $i + 1$.

- Hitung koefisien beta:

$$\beta_i = \frac{r_{i+1}^T r_{i+1}}{r_i^T r_i} \dots\dots\dots (III.13)$$

β_i : faktor pembobot yang mengatur seberapa banyak arah baru dipengaruhi oleh arah lama.

4. Update arah pencarian berikutnya:

$$p_{i+1} = r_{i+1} + \beta_i p_i \dots\dots\dots (III.14)$$

p_{i+1} : arah pencarian baru, kombinasi residual baru dengan arah lama.

Setelah iterasi Conjugate Gradient selesai, parameter jaringan diperbarui menggunakan solusi akhir (v) sebagai berikut:

$$\theta_{t+1} = \theta_t + \eta v \dots\dots\dots (III.15)$$

Parameter CG yang digunakan:

- Maksimum iterasi = 30 (*truncated CG*)
- Toleransi residual = 10^{-6}

d. Satu Iterasi HFO (HF Step)

Setiap iterasi HFO (setiap *epoch*) terdiri dari rangkaian langkah berikut:

1. Menghitung Gradien

- Hitung nilai *loss* pada parameter saat ini.
- Hitung gradien $g = \nabla \mathcal{L}(\theta)$ terhadap semua parameter menggunakan *backpropagation*.
- Flatten gradien menjadi vektor 1D.

2. Mencari Arah Pencarian dengan CG

- Definisikan operator linear $Av = (H + \lambda I)v$ menggunakan fungsi HVP.
- Selesaikan sistem linear $Ad = -g$ menggunakan algoritma CG.
- Hasilnya adalah arah pencarian d .

3. Menghitung Prediksi Reduksi

Hitung prediksi penurunan *loss* yang diprediksi oleh model kuadratik:

$$\text{pred_red} = -g^T d - \frac{1}{2} d^T A d \dots\dots\dots(\text{III.16})$$

Nilai ini digunakan untuk mengevaluasi kualitas model kuadratik lokal.

4. Backtracking Line Search (Armijo)

- Tujuan: mencari panjang langkah α yang optimal sehingga parameter baru benar-benar menurunkan *loss*.
- Inisialisasi $\alpha = 1,0$.
- Loop:
 - Perbarui parameter sementara: $\theta_{\text{temp}} = \theta + \alpha d$
 - Hitung *loss* baru.

- Jika $loss$ baru $< loss$ lama, terima langkah ini dan keluar dari loop.
- Jika tidak, batalkan langkah dan perkecil α (dikalikan 0,5).
- Ulangi hingga α sangat kecil ($< 10^{-6}$) atau $loss$ baru lebih kecil.
- Setelah ditemukan α yang memenuhi, perbarui parameter secara permanen.
- Langkah 5: Adaptasi Damping
- Hitung reduksi aktual: $act_red = \mathcal{L}_{old} - \mathcal{L}_{new}$
- Hitung rasio reduksi: $\rho = \frac{act_red}{pred_red}$
- Adaptasi parameter *damping* λ berdasarkan nilai ρ :
 - Jika $\rho > 0,75$: model kuadrat akurat $\rightarrow \lambda \leftarrow 0,5\lambda$ (lebih agresif)
 - Jika $\rho < 0,25$: model kuadrat tidak akurat $\rightarrow \lambda \leftarrow 2\lambda$ (lebih konservatif)
 - Jika $0,25 \leq \rho \leq 0,75$: λ tetap

5. Evaluasi Akurasi

- Hitung akurasi model pada data latih (atau data validasi) untuk memantau perkembangan performa.

e. Loop Training HFO

Pelatihan HFO dijalankan dalam loop selama *epoch* (*EarlyStopping*).

Setiap *epoch* menjalankan satu iterasi HFO penuh (satu kali *hf_step*).

Karakteristik pelatihan HFO:

- Mode full-batch: Seluruh data latih digunakan setiap iterasi (bukan mini-batch). Hal ini karena HFO membutuhkan evaluasi gradien dan Hessian yang akurat dari seluruh data.
- Satu epoch = satu update parameter: Berbeda dengan SGD yang satu epoch bisa terdiri dari puluhan atau ratusan mini-batch update, HFO hanya melakukan satu pembaruan parameter per epoch.
- Validasi: Setelah setiap *epoch*, model dievaluasi pada data validasi untuk memantau kinerja generalisasi dan mencegah *overfitting*.

f. Ringkasan Parameter HFO

Berdasarkan implementasi yang telah dijelaskan, parameter HFO yang digunakan dalam penelitian ini adalah sebagai berikut:

Tabel 3. 4 Parameter HFO

Parameter	Nilai	Keterangan
λ_0 (<i>damping</i> awal)	0,1	Parameter <i>damping</i> pada iterasi pertama
Maksimum iterasi CG	30	<i>Truncated CG</i> (dihentikan lebih awal demi efisiensi)
Toleransi residual CG	10^{-6}	Kriteria konvergensi CG
α_0 (panjang langkah awal)	1,0	Inisialisasi untuk <i>line search</i>
β (faktor <i>backtracking</i>)	0,5	Faktor pengurang α setiap langkah
$\alpha_{\min}$	10^{-8}	Panjang langkah minimum

Parameter	Nilai	Keterangan
Jumlah <i>epoch</i>	<i>Sampai dengan konvergen (EarlyStopping)</i>	Jumlah iterasi HFO
Mode pelatihan	<i>Full-batch</i>	Seluruh data latih per iterasi

3.8. Skenario Eksperimen

1. Skenario Perbandingan Optimizer

Skenario ini bertujuan untuk membandingkan kinerja empat algoritma optimisasi (SGDM, RMSProp, Adam, dan HFO) dalam melatih model DNN untuk tugas klasifikasi predikat kelulusan. Pada skenario ini, model dilatih menggunakan kombinasi seluruh fitur (akademik dan non-akademik) dengan arsitektur DNN yang sama.

Parameter pelatihan yang digunakan:

Tabel 3. 5 Parameter Pelatihan pada Skenario Perbandingan Optimizer

Parameter	SGDM	RMSProp	Adam	HFO
Learning Rate	0,001	0,001	0,001	Tidak digunakan
Momentum (μ)	0,9	-	-	-
β_1	-	-	0,9	-
β_2	-	-	0,999	-
Batch Size	32	32	32	Full Batch
Max Epoch	1000	1000	1000	1000
Early Stopping	Patience=30	Patience=30	Patience=30	Patience=30
Step Size	Tetap	Adaptif	Adaptif	Line Search
Random Seed	42	42	42	42

Tujuan skenario ini adalah untuk menjawab pernyataan masalah pertama, yaitu "Performa model prediksi menggunakan Neural Network dengan algoritma HFO

perlu dibandingkan dengan algoritma optimisasi konvensional seperti SGDM, RMSProp, dan Adam".

2. Skenario Studi Ablasi Fitur

Studi ablasi dilakukan untuk mengukur kontribusi tambahan variabel non-akademik terhadap performa model prediksi predikat kelulusan mahasiswa. Dalam skenario ini, dua model dengan komposisi fitur yang berbeda dibandingkan, namun keduanya dilatih menggunakan algoritma optimisasi yang sama, yaitu *Hessian-Free Optimization* (HFO). Pemilihan HFO sebagai *optimizer* tunggal dalam studi ablasi didasarkan pada hasil skenario perbandingan *optimizer*, di mana HFO menghasilkan performa terbaik dibandingkan SGDM, RMSProp, dan Adam. Dengan menggunakan *optimizer* yang sama, perbedaan performa yang dihasilkan dapat diatribusikan secara langsung pada perbedaan komposisi fitur, bukan pada pengaruh *optimizer*.

Model pertama, selanjutnya disebut sebagai Model A (Akademik + Non-Akademik), menggunakan seluruh fitur yang tersedia dalam penelitian ini. Fitur-fitur tersebut terdiri dari empat variabel akademik yaitu: IPS Semester 1, IPS Semester 2, IPS Semester 3, dan IPS Semester 4 serta delapan variabel non-akademik yang meliputi jenis kelamin, asal sekolah, pengalaman mondok di pesantren, jalur penerimaan mahasiswa baru (PMB), kemampuan Bahasa Arab, kemampuan Bahasa Inggris, kemampuan komputer, dan jurusan. Model A merepresentasikan skenario dengan informasi paling lengkap tentang latar belakang mahasiswa.

Model kedua, selanjutnya disebut sebagai Model B (Akademik saja), hanya menggunakan empat variabel akademik yaitu: IPS Semester 1, IPS Semester 2, IPS

Semester 3, dan IPS Semester 4 tanpa menyertakan variabel non-akademik. Model B berfungsi sebagai *baseline* dalam studi ablasi untuk mengukur sejauh mana kontribusi variabel non-akademik terhadap peningkatan performa prediksi.

Kedua model menggunakan arsitektur DNN yang sama (sebagaimana dijelaskan pada subbab 3.6) dengan parameter pelatihan yang identik, yaitu jumlah *epoch* sampai dengan konvergen menggunakan *EarlyStopping*, *random seed* 42 untuk reproduksibilitas, serta parameter HFO yang konsisten ($\lambda_0 = 0,1$, maksimum iterasi CG = 30, $\alpha_0 = 1,0$, dan $\beta = 0,5$).

Dengan membandingkan performa Model A dan Model B, penelitian ini dapat menjawab pernyataan masalah kedua, yaitu mengidentifikasi kontribusi prediktif variabel akademik dan non-akademik terhadap prediksi predikat kelulusan mahasiswa. Secara spesifik, studi ablasi akan mengukur apakah penambahan variabel non-akademik memberikan peningkatan akurasi, seberapa besar peningkatan tersebut, serta apakah peningkatan tersebut signifikan secara statistik dan praktis.

3.9. Metrik Evaluasi

Kinerja model dievaluasi menggunakan metrik klasifikasi multikelas berikut:

$$\text{Akurasi} : \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{Precision} : \frac{TP}{TP + FP}$$

$$\text{Recall} : \frac{TP}{TP + FN}$$

$$\text{F1-Score} \quad : \quad 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Untuk klasifikasi multikelas, precision, recall, dan F1-score dilaporkan dalam bentuk **weighted average**. Selain metrik di atas, *confusion matrix* juga dianalisis untuk melihat pola kesalahan klasifikasi antar kelas. Untuk tugas klasifikasi empat kelas, *confusion matrix* berukuran 4×4 yang menunjukkan jumlah prediksi benar dan salah untuk setiap kombinasi kelas aktual dan kelas prediksi.

BAB IV

HASIL DAN ANALISIS

4.1. Deskripsi Data

Data yang digunakan dalam penelitian ini merupakan data historis mahasiswa alumni Fakultas Sains dan Teknologi UIN Maulana Malik Ibrahim Malang angkatan tahun 2009–2021. Data diperoleh melalui sistem informasi akademik (SIKAD) fakultas dengan persetujuan pihak terkait, dan digunakan secara agregat untuk kepentingan penelitian akademik.

Secara keseluruhan, data historis mahasiswa alumni terdiri dari 6.929 baris data (observasi mahasiswa) dan 13 kolom variabel. Variabel-variabel tersebut merepresentasikan kombinasi faktor akademik dan non-akademik yang diasumsikan berpengaruh terhadap predikat kelulusan mahasiswa. Data-data yang berperan sebagai variabel independen ditampilkan dalam Tabel 4.1, yang merupakan data mentah sebelum proses pengolahan dilakukan.

4.1.1. Karakteristik Umum Dataset

Berdasarkan pengamatan awal terhadap data mentah, data tersebut memiliki beberapa karakteristik penting:

- Terdapat data kategorikal dengan variasi kelas cukup banyak, terutama pada variabel jalur PMB dan jenis sekolah.
- Terdapat nilai tidak lengkap yang ditandai dengan “NaN” pada sebagian variabel non-akademik.

Tabel 4.1 Ringkasan Data Mentah Alumni Fakultas Sains dan Teknologi Angkatan Tahun 2009 – 2021

	No	NIM	Nama Mahasiswa	Jenis Kelamin	Jenis Sekolah
1	1	9610001	ARNI HARTANTI	Perempuan	Sekolah Umum
2	2	9610002	IFA NOVIYANTI	Perempuan	Madrasah
3	3	9610003	ARINI HIDAYATI	Perempuan	Sekolah Umum
4	4	9610004	MAHATVA CAHYANINGTYAS	Perempuan	Sekolah Umum
5	5	9610005	EVA AYU SAFITRI	Perempuan	Sekolah Umum
...	...	...	...	...	...
6925	6925	210607110068	M. DAISAK SYAMAIDZAR	Laki-Laki	Madrasah
6926	6926	210607110069	SUCI MAULIDIA	Perempuan	Sekolah Umum
6927	6927	210607110070	MARTINDA ANJANT	Perempuan	Sekolah Umum
6928	6928	210607110071	RIZA FIRDIANSYAH	Laki-Laki	Sekolah Umum
6929	6929	210607110072	EGA ANASYA PUTRI	Perempuan	Madrasah

	Pernah Mondok	Jalur PMB	Kemampuan Bahasa Arab	Kemampuan Bahasa Inggris	Kemampuan Komputer
1	Tidak	Mandiri	Tidak Bisa	Aktif	Operator
2	Tidak	Mandiri	Pasif	Pasif	Operator
3	Ya	Mandiri	Pasif	Aktif	Operator
4	Tidak	Seleksi Nasional	-	-	-
5	Tidak	Seleksi Nasional	-	-	-
...	...	...	...	...	...
6925	Tidak	Mandiri	Pasif	Pasif	Operator
6926	Tidak	Beasiswa	Pasif	Pasif	Operator
6927	Tidak	Beasiswa	Tidak Bisa	Pasif	Operator
6928	Tidak	Mandiri	Pasif	Pasif	Operator
6929	Ya	Mandiri	Pasif	Aktif	Programer

	Jurusan	IPS1	IPS2	IPS3	IPS4	Predikat
1	Matematika	3,78	3,44	3,44	3,17	Sangat Memuaskan
2	Matematika	3,54	3,15	3,19	3,07	Sangat Memuaskan
3	Matematika	3,54	3,42	3,29	3,41	Sangat Memuaskan
4	Matematika	2,98	2,66	2,95	2,9	Sangat Memuaskan
5	Matematika	3,63	3,17	3,23	2,83	Sangat Memuaskan
...	...	...	...	...	...	...
6925	Perpustakaan & Sains Informasi	3,68	3,75	3,63	3,71	Cumlaude
6926	Perpustakaan & Sains Informasi	3,66	3,69	3,76	3,83	Cumlaude
6927	Perpustakaan & Sains Informasi	3,7	3,83	3,78	3,93	Cumlaude
6928	Perpustakaan & Sains Informasi	3,34	3,1	3,46	3,25	Sangat Memuaskan
6929	Perpustakaan & Sains Informasi	3,57	3,56	3,72	3,5	Cumlaude

- Distribusi kelas pada variabel target tidak sepenuhnya seimbang, dengan dominasi predikat Sangat Memuaskan dan Cumlaude, yang mencerminkan kondisi riil lulusan fakultas.

Karakteristik tersebut menuntut adanya tahapan pra-pemrosesan data yang cermat, meliputi imputasi data, encoding variabel kategorikal, serta normalisasi variabel numerik sebelum digunakan dalam pemodelan DNN.

4.1.2. Relevansi Data terhadap Tujuan Penelitian

Data yang digunakan dalam penelitian ini dinilai relevan dan memadai untuk menjawab tujuan penelitian karena beberapa alasan. Pertama, data menggabungkan informasi akademik (IPS semester 1–4) dan non-akademik (latar belakang pendidikan, kemampuan bahasa, jalur masuk, dll.) secara komprehensif, sehingga memungkinkan pengujian kontribusi kedua kelompok variabel terhadap predikat kelulusan. Kedua, jumlah data yang cukup besar (6.929 observasi) memadai untuk pelatihan model Deep Neural Network yang membutuhkan data dalam skala besar. Ketiga, data mengandung variabel khas perguruan tinggi Islam (pengalaman mondok, kemampuan bahasa Arab) yang mendukung aspek kebaruan penelitian. Keempat, variabel target terdiri dari empat kategori predikat kelulusan, sehingga memungkinkan penerapan klasifikasi multikelas sesuai dengan tujuan penelitian.

4.2. Prapemrosesan Data

Tahap pra-pemrosesan data dilakukan untuk memastikan data yang digunakan dalam pelatihan model Deep Neural Network (DNN) berada dalam kondisi bersih,

konsisten, dan sesuai dengan kebutuhan algoritma. Seluruh proses dirancang untuk menghindari *data leakage* (parameter imputasi, *encoding*, dan *scaling* hanya dihitung dari data latih).

4.2.1. Pembersihan dan Imputasi Data

Langkah-langkah pembersihan data yang dilakukan:

1. Simbol "-" pada data mentah dikonversi menjadi nilai NaN (*Not a Number*).
2. Pada variabel kategorikal, nilai kosong diimputasi menggunakan **modus** (nilai paling sering muncul) yang dihitung dari data latih.
3. Pada variabel numerik (IPS 1–4), nilai kosong diimputasi menggunakan **median** yang dihitung dari data latih.

Hasil dari proses pembersihan dan imputasi menghasilkan dataset bersih yang terdiri dari 6.929 baris data dan 13 kolom variabel (12 variabel prediktor + 1 variabel target). Seluruh variabel pada dataset akhir tidak lagi mengandung nilai kosong.

Tabel 4. 2 Ringkasan Dataset Alumni Fakultas Sains dan Teknologi Angkatan Tahun 2009 – 2021

	No	Jenis Kelamin	Jenis Sekolah	Pernah Mondok	Jalur PMB	Kemampuan Bahasa Arab
1	1	Perempuan	Sekolah Umum	Tidak	Mandiri	Tidak Bisa
2	2	Perempuan	Madrasah	Tidak	Mandiri	Pasif
3	3	Perempuan	Sekolah Umum	Ya	Mandiri	Pasif
4	4	Perempuan	Sekolah Umum	Tidak	Seleksi Nasional	Pasif
5	5	Perempuan	Sekolah Umum	Tidak	Seleksi Nasional	Pasif
...	...	...	...	...	...	...
6925	6925	Laki-laki	Madrasah	Tidak	Mandiri	Pasif
6926	6926	Perempuan	Sekolah Umum	Tidak	Beasiswa	Pasif
6927	6927	Perempuan	Sekolah Umum	Tidak	Beasiswa	Tidak Bisa
6928	6928	Laki-laki	Sekolah Umum	Tidak	Mandiri	Pasif
6929	6929	Perempuan	Madrasah	Ya	Mandiri	Pasif

No	Kemampuan Bahasa Inggris	Kemampuan Komputer	Jurusan	IPS1	IPS2	IPS3	IPS4	Predikat
1	Aktif	Operator	Matematika	3,78	3,44	3,44	3,17	Sangat Memuaskan
2	Pasif	Operator	Matematika	3,54	3,15	3,19	3,07	Sangat Memuaskan
3	Aktif	Operator	Matematika	3,54	3,42	3,29	3,41	Sangat Memuaskan
4	Pasif	Operator	Matematika	2,98	2,66	2,95	2,9	Sangat Memuaskan
5	Pasif	Operator	Matematika	3,63	3,17	3,23	2,83	Sangat Memuaskan
'''	'''	'''	'''	'''	'''	'''	'''	'''
6925	Pasif	Operator	Perpustakaan & Sains Informasi	3,68	3,75	3,63	3,71	Cumlaude
6926	Pasif	Operator	Perpustakaan & Sains Informasi	3,66	3,69	3,76	3,83	Cumlaude
6927	Pasif	Operator	Perpustakaan & Sains Informasi	3,7	3,83	3,78	3,93	Cumlaude
6928	Pasif	Operator	Perpustakaan & Sains Informasi	3,34	3,1	3,46	3,25	Sangat Memuaskan
6929	Aktif	Programer	Perpustakaan & Sains Informasi	3,57	3,56	3,72	3,5	Cumlaude

a. Struktur dan Dimensi Dataset

Struktur dataset penelitian dapat dirangkum sebagai berikut:

- Jumlah data (observasi): 6.929 mahasiswa
- Jumlah variabel: 13 variabel
 - 12 variabel input (fitur)
 - 1 variabel output (label/target)

Dataset ini bersifat multivariat dan heterogen, karena mengandung:

- Variabel kategorikal
- Variabel numerik kontinu

Kombinasi ini mencerminkan kompleksitas data dunia nyata dalam konteks pendidikan tinggi.

b. Variabel Penelitian

1) Variabel Target

Variabel target dalam penelitian ini adalah Predikat Kelulusan, yang diklasifikasikan ke dalam empat kelas, yaitu: Cumlaude, Sangat Memuaskan, Memuaskan dan Cukup. Variabel ini bersifat kategorikal nominal dan menjadi output dari model klasifikasi multikelas Deep Neural Network (DNN).

2) Variabel Prediktor

Variabel prediktor terdiri dari dua kelompok utama, yaitu variabel akademik dan variabel non-akademik.

- Variabel Akademik

Variabel akademik direpresentasikan oleh nilai Indeks Prestasi Semester (IPS) pada empat semester awal, yaitu: IPS 1, IPS 2, IPS 3 dan IPS 4. Keempat variabel ini bersifat numerik kontinu, dengan rentang nilai sekitar 0,00–4,00. IPS semester awal dipilih karena mencerminkan performa akademik mahasiswa pada fase awal masa studi dan memiliki korelasi kuat terhadap capaian akademik akhir.

- Variabel Non-Akademik

Variabel non-akademik mencakup karakteristik latar belakang dan kompetensi mahasiswa, yang dijelaskan sebagai berikut:

1. Jenis Kelamin

- Kategori: Laki-laki, Perempuan

2. Jenis Asal Sekolah

- Kategori: Madrasah dan Sekolah Umum

3. Pengalaman Mondok di Pesantren

- Kategori: Ya, Tidak

4. Jalur Penerimaan Mahasiswa Baru (PMB)

- Kategori: Beasiswa, Mandiri, Seleksi Nasional, Seleksi PTKIN dan Transfer

5. Kemampuan Bahasa Arab

- Kategori: Tidak Bisa, Pasif, Aktif, Mahir

6. Kemampuan Bahasa Inggris

- Kategori: Tidak Bisa, Pasif, Aktif, Mahir

7. Kemampuan Komputer

- Kategori: Tidak Bisa, Operator, Programmer

8. Jurusan

- Kategori: Matematika, Biologi, Kimia, Fisika, Teknik Informatika, Teknik Arsitektur dan Perpustakaan dan Sains Informasi

Variabel-variabel non-akademik ini menjadi ciri khas penelitian karena merepresentasikan konteks perguruan tinggi Islam, khususnya pengalaman mondok dan kemampuan Bahasa Arab yang jarang digunakan dalam penelitian EDM sebelumnya.

4.2.2. Pembagian Dataset (Data Splitting)

Setelah proses pembersihan data, dataset dibagi menjadi tiga bagian utama, yaitu data latih (training set), data validasi (validation set), dan data uji (testing set). Pembagian data dilakukan secara stratified sampling berdasarkan label target untuk menjaga proporsi kelas pada setiap subset.

Tabel 4. 3 Pembagian Dataset

Subset	Proporsi	Jumlah Data
Data Latih (<i>Training</i>)	60%	4.157
Data Validasi (<i>Validation</i>)	20%	1.386
Data Uji (<i>Testing</i>)	20%	1.386
Total	100%	6.929

Pembagian dilakukan secara bertahap:

1. Seluruh dataset dibagi menjadi 80% data latih sementara dan 20% data uji.
2. Data latih sementara (80%) dibagi menjadi 75% data latih dan 25% data validasi, sehingga menghasilkan proporsi akhir 60:20:20.

4.2.3. Transformasi Variabel (Encoding dan Scaling)

Variabel prediktor dipisahkan berdasarkan tipe datanya menjadi:

- Variabel kategorikal, yaitu seluruh variabel bertipe objek (string)
 - Variabel numerik, yaitu variabel IPS semester 1 sampai dengan semester 4
- Encoding Variabel Kategorikal

Seluruh variabel kategorikal dalam penelitian ini diperlakukan sebagai kategorikal nominal, tanpa mempertimbangkan adanya tingkatan atau urutan nilai. Untuk mengubah variabel kategorikal nominal menjadi bentuk numerik, digunakan teknik One-Hot Encoding. Teknik ini mengubah setiap kategori menjadi vektor biner (0 dan 1), sehingga tidak menimbulkan hubungan numerik semu antar kategori.

One-Hot Encoding diterapkan pada variabel: Jenis kelamin, Jenis asal sekolah, Pengalaman mondok, Jalur PMB, Kemampuan Bahasa Arab, Kemampuan Bahasa Inggris, Kemampuan komputer, dan Jurusan. Pendekatan ini dipilih karena seluruh

variabel kategorikal dianggap tidak memiliki hubungan hierarkis, One-Hot Encoding aman digunakan pada model neural network, dan tidak mengasumsikan urutan atau jarak antar kategori.

- Scaling Variabel Numerik

Variabel numerik (IPS 1–IPS 4) dinormalisasi menggunakan metode *StandardScaler (Z-Score Normalization)*, yang mengubah data sehingga memiliki rata-rata 0 dan standar deviasi 1.

Normalisasi dilakukan untuk:

- Menyamakan skala antar fitur
- Mempercepat konvergensi pelatihan DNN
- Menghindari dominasi fitur dengan skala numerik lebih besar

Sementara itu, fitur hasil one-hot encoding tidak dilakukan scaling karena telah berada pada rentang nilai 0 dan 1.

Seluruh proses encoding dan scaling dilakukan secara terintegrasi menggunakan *ColumnTransformer*, sehingga transformasi yang sama dapat diterapkan secara konsisten pada data latih, validasi, dan uji. Setelah *one-hot encoding* dan *scaling*, dimensi input model menjadi 33 fitur numerik (4 IPS yang telah di-scale + 29 fitur biner hasil *one-hot encoding*).

4.2.4. Transformasi dan Penyiapan Label Target

Variabel target berupa predikat kelulusan mahasiswa terdiri dari empat kelas, yaitu: Cukup, Memuaskan, Sangat Memuaskan dan Cumlaude. Label target dipetakan

ke bentuk numerik pada Tabel 4.4 menggunakan skema pengkodean untuk keperluan pemodelan.

Tabel 4. 4 Pemetaan Label Target ke Kode Numerik dan One-Hot Encoding

Predikat	Kode Numerik	Kode One-Hot
Cukup	0	[1, 0, 0, 0]
Memuaskan	1	[0, 1, 0, 0]
Sangat Memuaskan	2	[0, 0, 1, 0]
Cumlaude	3	[0, 0, 0, 1]

Selain itu, dari hasil distribusi label sebagaimana Table 4.5 diketahui adanya ketidakseimbangan jumlah data antar kelas.

Tabel 4. 5 Distribusi Label

Predikat	Kode Numerik	Jumlah Data	Persentase
Cukup	0	23	0,33%
Memuaskan	1	287	4,14%
Sangat Memuaskan	2	3.927	56,68%
Cumlaude	3	2.692	38,85%
Total	-	6.929	100%

4.2.5. Hasil Akhir Pra-Pemrosesan Data

Setelah seluruh tahapan pra-pemrosesan dilakukan, diperoleh dataset dengan karakteristik sebagai berikut:

- Seluruh fitur berada dalam bentuk numerik
- Tidak terdapat nilai kosong
- Distribusi kelas tetap terjaga melalui stratified splitting
- Dimensi input model meningkat akibat penerapan one-hot encoding

- Dataset siap digunakan untuk pelatihan dan evaluasi model DNN dengan berbagai algoritma optimisasi

Tahap pra-pemrosesan ini memastikan bahwa data yang digunakan telah memenuhi persyaratan teknis dan metodologis untuk mendukung proses pemodelan Deep Neural Network secara optimal.

4.3. Analisis Kontribusi Variabel (Pearson Correlation)

Analisis kontribusi variabel dilakukan untuk memperoleh gambaran awal mengenai hubungan linear antara variabel prediktor dan variabel target, yaitu predikat kelulusan mahasiswa. Metode yang digunakan pada tahap ini adalah koefisien korelasi Pearson, yang mengukur kekuatan dan arah hubungan linear antara dua variabel numerik.

Perlu ditegaskan bahwa pada penelitian ini Gambar 4.1 Korelasi Fitur terhadap Target merupakan analisis *Pearson Correlation* yang bersifat eksploratif, sehingga hasilnya tidak digunakan untuk seleksi fitur secara langsung, melainkan sebagai dasar pemahaman awal karakteristik data sebelum dilakukan pemodelan menggunakan Deep Neural Network (DNN).


4.3.1. Penerapan *Pearson Correlation* pada Dataset

Analisis korelasi dilakukan setelah seluruh data melalui tahap pra-pemrosesan, yaitu:

- Seluruh variabel kategorikal ditransformasikan ke bentuk numerik menggunakan *One-Hot Encoding*
- Variabel numerik telah dinormalisasi menggunakan *StandardScaler*

- Variabel target (predikat kelulusan) telah dipetakan ke dalam bentuk numerik

Dengan kondisi tersebut, seluruh fitur hasil transformasi dapat dianalisis korelasinya terhadap target menggunakan *Pearson Correlation*.



Gambar 4. 1 Korelasi Fitur terhadap Target

4.3.2. Hasil Analisis Korelasi Variabel Akademik

Berdasarkan hasil analisis yang ditunjukkan pada Gambar 4.1 mengenai korelasi fitur terhadap target *Predikat*, variabel akademik berupa Indeks Prestasi Semester (IPS) menunjukkan nilai korelasi paling tinggi dibandingkan variabel lainnya. Nilai koefisien korelasi Pearson untuk masing-masing semester adalah sebagai berikut:

- IPS Semester 3 : 0,61
- IPS Semester 4 : 0,61
- IPS Semester 2 : 0,56
- IPS Semester 1 : 0,56

Nilai tersebut menunjukkan hubungan positif dengan kategori sedang hingga kuat, yang mengindikasikan bahwa semakin tinggi capaian IPS mahasiswa, maka semakin besar kecenderungan mahasiswa memperoleh predikat kelulusan yang lebih tinggi. IPS semester 3 dan 4 memiliki korelasi tertinggi (0,61), menunjukkan bahwa performa akademik pada pertengahan masa studi memiliki hubungan linear paling kuat terhadap capaian akhir mahasiswa.

Temuan ini menegaskan bahwa konsistensi performa akademik dari semester awal hingga pertengahan merupakan faktor dominan dalam menentukan predikat kelulusan. Dengan demikian, variabel akademik menjadi indikator utama dalam proses prediksi.

4.3.3. Hasil Analisis Korelasi Variabel Non-Akademik

Berbeda dengan variabel akademik, variabel non-akademik menunjukkan nilai korelasi yang relatif lebih rendah. Beberapa fitur non-akademik dengan korelasi positif tertinggi adalah:

- Jurusan Teknik Informatika : 0,14
- Jenis Kelamin Perempuan : 0,14
- Jurusan Perpustakaan dan Sains Informasi : 0,11
- Kemampuan Bahasa Arab (Tidak Bisa) : 0,10

- Jalur PMB Seleksi Nasional : 0,10
- Pernah Mondok (Tidak) : 0,09

Nilai korelasi tersebut menunjukkan adanya kecenderungan hubungan positif, meskipun kekuatannya tergolong lemah dibandingkan variabel akademik.

Sebaliknya, beberapa fitur non-akademik menunjukkan korelasi negatif, antara lain:

- Jenis Kelamin Laki-laki : -0,14
- Jalur PMB Mandiri : -0,12
- Pernah Mondok (Ya) : -0,09
- Jurusan Kimia : -0,08
- Jurusan Teknik Arsitektur : -0,07
- Jurusan Fisika : -0,06

Selain itu, beberapa kategori kemampuan bahasa dan komputer tertentu juga menunjukkan korelasi negatif kecil (sekitar -0,01 hingga -0,05), yang mengindikasikan hubungan linear yang sangat lemah terhadap predikat kelulusan.

Nilai korelasi negatif ini menunjukkan adanya kecenderungan hubungan terbalik secara linear, namun tidak dapat diartikan sebagai hubungan sebab-akibat, mengingat *Pearson Correlation* hanya mengukur kekuatan hubungan linear sederhana.

4.3.4. Interpretasi Hasil Korelasi

Secara umum, hasil analisis Pearson Correlation menunjukkan bahwa:

- a. Variabel akademik (IPS 1–4) merupakan prediktor utama secara linear terhadap predikat kelulusan, dengan nilai korelasi tertinggi mencapai 0,61.

- b. Variabel non-akademik memiliki kontribusi linear yang relatif lemah ($|r| < 0,15$), namun tetap memberikan informasi tambahan yang berpotensi memperkaya model prediksi.
- c. Rendahnya korelasi linear pada variabel non-akademik mengindikasikan bahwa pengaruhnya kemungkinan bersifat:
- Non-linear
 - Kontekstual
 - Melibatkan interaksi antar variabel

Oleh karena itu, penggunaan pendekatan Deep Neural Network (DNN) menjadi relevan, karena model ini mampu menangkap pola non-linear dan interaksi kompleks antar variabel yang tidak dapat dijelaskan hanya melalui analisis korelasi linear.


Berdasarkan hasil analisis ini dapat disimpulkan bahwa faktor akademik, khususnya IPS semester awal hingga pertengahan, memiliki pengaruh linear paling kuat terhadap predikat kelulusan mahasiswa. Sementara itu, faktor non-akademik berperan sebagai variabel pendukung yang dapat meningkatkan kemampuan generalisasi model ketika diproses menggunakan metode pembelajaran mendalam.


Analisis korelasi ini berfungsi sebagai analisis pendahuluan, sedangkan evaluasi kontribusi variabel secara komprehensif akan ditentukan melalui hasil pelatihan dan pengujian model Deep Neural Network dengan berbagai algoritma optimisasi pada subbab selanjutnya.

4.4. Hasil Evaluasi Model Deep Neural Network

Evaluasi model dilakukan untuk menilai performa prediksi predikat kelulusan mahasiswa menggunakan Deep Neural Network (DNN) dengan beberapa algoritma optimisasi, yaitu Stochastic Gradient Descent with Momentum (SGD+Momentum), RMSProp, Adam, dan Hessian-Free Optimization (HFO). Evaluasi dilakukan menggunakan kurva loss serta akurasi per epoch dan data uji (testing set) dengan metrik akurasi, precision, recall, dan F1-score, serta dianalisis lebih lanjut melalui confusion matrix.

4.4.1. Analisis Kurva Loss dan Akurasi





Gambar 4. 2 Kurva Loss dan Akurasi per Epoch

Analisis kurva loss per epoch dan akurasi per epoch dilakukan untuk mengevaluasi proses pembelajaran model *Deep Neural Network* (DNN) selama pelatihan dan validasi. Kurva ini digunakan untuk mengamati kecepatan konvergensi, stabilitas optimisasi, serta kemampuan generalisasi dari masing-masing algoritma optimisasi yang diuji, yaitu SGD dengan Momentum, RMSProp, Adam, dan Hessian-Free Optimization (HFO). Seluruh model dilatih sampai mencapai konvergen menggunakan metode *EarlyStopping* dengan arsitektur dan parameter pelatihan yang sama.

Berdasarkan hasil analisis terhadap keempat optimizer (SGDM, RMSProp, Adam, dan HFO) yang dilatih sampai dengan konvergen dengan arsitektur dan parameter yang sama sebagaimana Gambar 4.2, maka diperoleh ringkasan perilaku konvergensi yang disajikan pada Tabel 4.6 berikut.

Tabel 4. 6 Ringkasan Perilaku Konvergensi Setiap Optimizer

Optimizer	Train Accuracy	Validation Accuracy	Train Loss	Validation Loss	Konvergen pada Epoch
HFO	0,8641	0,8362	0,4006	0,3576	61
RMSProp	0,7024	0,7893	0,7474	0,4691	360
Adam	0,7217	0,7857	0,5181	0,4707	380
SGDM	0,6979	0,7771	0,7234	0,5407	523

Berdasarkan hasil pelatihan model Deep Neural Network (DNN) menggunakan empat algoritma optimisasi, yaitu Hessian-Free Optimization (HFO), Stochastic Gradient Descent (SGD), RMSProp, dan Adam, diperoleh bahwa HFO menunjukkan performa terbaik secara keseluruhan. Model dengan optimizer HFO menghasilkan akurasi pelatihan sebesar 86,41% dan akurasi validasi sebesar 83,62%, yang merupakan nilai tertinggi dibandingkan optimizer lainnya. Selain itu, HFO juga menghasilkan nilai loss pelatihan terendah sebesar 0,4006 dan loss validasi terendah sebesar 0,3576.

Dari aspek konvergensi, HFO mencapai kondisi optimal pada epoch ke-61, jauh lebih cepat dibandingkan RMSProp (epoch ke-360), Adam (epoch ke-380), dan SGD (epoch ke-523). Hasil ini menunjukkan bahwa HFO mampu menemukan solusi yang lebih baik dengan jumlah iterasi yang lebih sedikit. Keunggulan tersebut berasal dari penggunaan informasi kelengkungan (curvature) fungsi loss melalui pendekatan optimisasi orde kedua (second-order optimization), sehingga arah pembaruan parameter dapat ditentukan secara lebih akurat dibandingkan metode optimisasi berbasis gradien orde pertama.

Optimizer RMSProp menempati posisi kedua dengan akurasi validasi sebesar 78,93% dan loss validasi sebesar 0,4691. Meskipun mampu menghasilkan performa

yang cukup baik, RMSProp membutuhkan jumlah epoch yang jauh lebih besar untuk mencapai konvergensi. Adam menghasilkan akurasi validasi sebesar 78,57% dengan loss validasi sebesar 0,4707. Performa Adam relatif sebanding dengan RMSProp, namun memerlukan epoch yang sedikit lebih banyak sebelum memenuhi kriteria penghentian pelatihan. Sementara itu, SGD menunjukkan performa terendah dengan akurasi validasi sebesar 77,71% dan loss validasi sebesar 0,5407, serta membutuhkan 523 epoch untuk mencapai kondisi konvergen.

Secara keseluruhan, hasil penelitian menunjukkan bahwa Hessian-Free Optimization (HFO) merupakan optimizer yang paling efektif untuk kasus prediksi predikat kelulusan mahasiswa. HFO tidak hanya menghasilkan akurasi dan loss terbaik, tetapi juga mampu mencapai konvergensi lebih cepat dibandingkan optimizer first-order lainnya. Oleh karena itu, HFO dipilih sebagai optimizer terbaik untuk digunakan pada tahap studi ablasi fitur guna mengevaluasi kontribusi relatif variabel akademik dan non-akademik terhadap performa prediksi predikat kelulusan mahasiswa.

4.4.2. Evaluasi Kinerja Model DNN

Evaluasi kinerja model *Deep Neural Network* (DNN) pada penelitian ini dilakukan untuk menilai kemampuan model dalam memprediksi predikat kelulusan mahasiswa secara kuantitatif dan komprehensif. Evaluasi difokuskan pada metrik klasifikasi yang umum digunakan dalam permasalahan klasifikasi multikelas, yaitu accuracy, precision, recall, dan F1-score. Selain itu, analisis juga dilengkapi dengan confusion matrix untuk memberikan gambaran yang lebih rinci mengenai pola prediksi

benar dan kesalahan klasifikasi pada setiap kelas predikat kelulusan. Pembahasan pada subbab ini disajikan secara bertahap untuk masing-masing algoritma optimisasi yang digunakan, yaitu SGD dengan Momentum, RMSProp, Adam, dan Hessian-Free Optimization (HFO), sehingga perbedaan kinerja antar model dapat dianalisis secara sistematis dan mendalam.

a. Evaluasi Kinerja Model DNN menggunakan SGD dengan Momentum


Evaluasi kinerja model Deep Neural Network (DNN) dengan optimizer Stochastic Gradient Descent menggunakan Momentum (SGD+Momentum) dilakukan untuk menilai kemampuan model dalam memprediksi predikat kelulusan mahasiswa pada data uji.

Tabel 4. 7 Hasil Evaluasi Model DNN dengan SGD + Momentum

Metrik	Nilai
Accuracy	0,8016 (80,16%)
Precision	0,8496
Recall	0,8016
F1-Score	0,8173

Tabel 4. 8 Classification Report SGD + Momentum

Kelas	Precision	Recall	F1-Score	Support
Cukup	0,20	0,40	0,27	5
Memuaskan	0,28	0,75	0,41	60
Sangat Memuaskan	0,90	0,75	0,82	785
Cumlaude	0,85	0,88	0,87	536
Accuracy	-	-	0,80	1386
Macro Average	0,56	0,70	0,59	1386
Weighted Average	0,85	0,80	0,82	1386



Gambar 4. 3 Confusion Matrix — SGD+Momentum

Berdasarkan hasil pengujian pada 1.386 data uji, model Deep Neural Network (DNN) dengan optimizer Stochastic Gradient Descent with Momentum (SGD+Momentum) Tabel 4.7 menghasilkan akurasi sebesar 80,16%, dengan nilai precision 0,8496, recall 0,8016, dan F1-score 0,8173. Secara keseluruhan, model menunjukkan performa yang cukup baik dalam memprediksi predikat kelulusan mahasiswa, terutama pada kelas mayoritas. Nilai weighted average F1-score sebesar 0,82 mengindikasikan bahwa model mampu melakukan klasifikasi dengan tingkat ketepatan yang baik pada sebagian besar data uji.

Analisis per kelas Tabel 4.8 menunjukkan bahwa performa terbaik dicapai pada kelas Cumlaude dengan precision 0,85, recall 0,88, dan F1-score 0,87, diikuti oleh kelas Sangat Memuaskan dengan F1-score 0,82. Sebaliknya, performa pada kelas minoritas masih relatif rendah. Kelas Cukup hanya memperoleh F1-score 0,27, sedangkan kelas Memuaskan memperoleh F1-score 0,41. Meskipun recall pada kedua kelas tersebut cukup tinggi, nilai precision yang rendah menunjukkan bahwa masih

banyak prediksi yang salah akibat tumpang tindih dengan kelas lain. Perbedaan antara macro average F1-score sebesar 0,59 dan weighted average F1-score sebesar 0,82 menunjukkan adanya ketidakseimbangan performa antar kelas. Hal ini mengindikasikan bahwa model lebih efektif dalam mengenali kelas mayoritas dibandingkan kelas minoritas. Dengan demikian, meskipun SGD+Momentum mampu menghasilkan performa keseluruhan yang cukup baik, model masih menghadapi tantangan dalam menangani distribusi data yang tidak seimbang, terutama pada kelas dengan jumlah sampel yang sangat sedikit.

Berdasarkan confusion matrix Gambar 4.3, sebagian besar data berhasil diklasifikasikan dengan benar pada kelas Sangat Memuaskan (592 data) dan Cumlaude (472 data). Kesalahan klasifikasi terbesar terjadi pada kelas Sangat Memuaskan yang diprediksi sebagai Memuaskan sebanyak 107 data dan sebagai Cumlaude sebanyak 82 data, serta pada kelas Cumlaude yang diprediksi sebagai Sangat Memuaskan sebanyak 58 data. Pola ini menunjukkan bahwa model masih mengalami kesulitan dalam membedakan kelas-kelas yang memiliki karakteristik akademik berdekatan, khususnya antara Memuaskan, Sangat Memuaskan, dan Cumlaude. Meskipun demikian, mayoritas kesalahan terjadi pada kelas yang berdekatan secara ordinal, sehingga secara keseluruhan model DNN dengan optimizer SGD+Momentum mampu memberikan performa klasifikasi yang cukup baik dan layak digunakan sebagai baseline untuk dibandingkan dengan optimizer lainnya.

b. Evaluasi Kinerja Model DNN Menggunakan RMSProp


Evaluasi kinerja model Deep Neural Network (DNN) dengan optimizer Root Mean Square Propagation (RMSProp) dilakukan untuk menilai peningkatan performa prediksi predikat kelulusan mahasiswa dibandingkan model sebelumnya yang menggunakan SGD dengan Momentum.

Tabel 4. 9 Hasil Evaluasi Model DNN dengan RMSProp

Metrik	Nilai
Accuracy	0,8110 (81,10%)
Precision	0,8418
Recall	0,8110
F1-Score	0,8168

Tabel 4. 10 Classification Report RMSProp

Kelas	Precision	Recall	F1-Score	Support
Cukup	0,00	0,00	0,00	5
Memuaskan	0,35	0,67	0,46	60
Sangat Memuaskan	0,92	0,75	0,82	785
Cumlaude	0,79	0,93	0,86	536
Accuracy	-	-	0,81	1386
Macro Average	0,51	0,59	0,53	1386
Weighted Average	0,84	0,81	0,82	1386



Gambar 4. 4 Confusion Matrix — RMSProp

Berdasarkan hasil pengujian pada 1.386 data uji, model Deep Neural Network (DNN) dengan optimizer Root Mean Square Propagation (RMSProp) Tabel 4.9 menghasilkan akurasi sebesar 81,10%, dengan nilai precision 0,8418, recall 0,8110, dan F1-score 0,8168. Dibandingkan dengan SGD+Momentum yang memperoleh akurasi 80,16%, RMSProp menunjukkan peningkatan performa meskipun relatif kecil. Nilai weighted average F1-score sebesar 0,82 menunjukkan bahwa model secara umum mampu melakukan klasifikasi dengan baik pada data uji. Namun, nilai macro average F1-score sebesar 0,53 mengindikasikan masih adanya kesenjangan performa antara kelas mayoritas dan kelas minoritas akibat ketidakseimbangan distribusi data. Dari sisi performa per kelas Tabel 4.10, RMSProp menunjukkan hasil yang sangat baik pada kelas Sangat Memuaskan (F1-score 0,82) dan Cumlaude (F1-score 0,86), dengan 585 dari 785 data Sangat Memuaskan dan 499 dari 536 data Cumlaude berhasil diklasifikasikan dengan benar. Sebaliknya, model gagal mengenali kelas Cukup (F1-score 0,00), sementara pada kelas Memuaskan diperoleh F1-score sebesar 0,46 dengan 40 dari 60 data berhasil diprediksi secara tepat. Berdasarkan confusion matrix Gambar 4.4, kesalahan klasifikasi terbesar terjadi antara kelas Sangat Memuaskan dan Cumlaude, yaitu 132 data Sangat Memuaskan diprediksi sebagai Cumlaude dan 33 data Cumlaude diprediksi sebagai Sangat Memuaskan. Secara keseluruhan, RMSProp menunjukkan performa yang sedikit lebih baik dibandingkan SGD+Momentum, terutama dalam meningkatkan akurasi keseluruhan dan mempertahankan precision yang tinggi pada kelas mayoritas melalui mekanisme adaptive learning rate yang dimilikinya.

c. Evaluasi Kinerja Model DNN Menggunakan Adam


Evaluasi kinerja model Deep Neural Network (DNN) dengan optimizer Adaptive Moment Estimation (Adam) dilakukan untuk menilai efektivitas algoritma optimisasi adaptif berbasis momentum dan estimasi gradien orde pertama dalam memprediksi predikat kelulusan mahasiswa.

Tabel 4. 11 Hasil Evaluasi Model DNN dengan Adam

Metrik	Nilai
Accuracy	0,8045 (80,45%)
Precision	0,8564
Recall	0,8045
F1-Score	0,8205

Tabel 4. 12 Classification Report Adam

Kelas	Precision	Recall	F1-Score	Support
Cukup	0,20	0,40	0,27	5
Memuaskan	0,27	0,75	0,40	60
Sangat Memuaskan	0,91	0,75	0,82	785
Cumlaude	0,85	0,90	0,87	536
Accuracy	-	-	0,80	1386
Macro Average	0,56	0,70	0,59	1386
Weighted Average	0,86	0,80	0,82	1386



Gambar 4. 5 confusion matrix - Adam

Berdasarkan hasil pengujian pada 1.386 data uji, model Deep Neural Network (DNN) dengan optimizer Adaptive Moment Estimation (Adam) Tabel 4.11 menghasilkan akurasi sebesar 80,45%, dengan nilai precision 0,8564, recall 0,8045, dan F1-score 0,8205. Secara umum Tabel 4.12 Classification Report Adam, model menunjukkan performa yang baik dengan weighted average F1-score sebesar 0,82, namun nilai macro average F1-score sebesar 0,59 menunjukkan masih adanya kesenjangan performa antara kelas mayoritas dan kelas minoritas akibat ketidakseimbangan distribusi data. Pada kelas mayoritas, Adam mampu memberikan hasil yang baik, terutama pada kelas Cumlaude dengan F1-score 0,87 dan kelas Sangat Memuaskan dengan F1-score 0,82. Sementara itu, pada kelas minoritas, performa model masih relatif rendah meskipun mampu mengenali sebagian data kelas Cukup (recall 0,40) dan Memuaskan (recall 0,75). Berdasarkan confusion matrix Gambar 4.5, kesalahan klasifikasi terbesar terjadi pada kelas Sangat Memuaskan yang diprediksi sebagai Memuaskan sebanyak 111 data dan sebagai Cumlaude sebanyak 87 data, serta pada kelas Cumlaude yang diprediksi sebagai Sangat Memuaskan sebanyak 48 data. Temuan ini menunjukkan bahwa Adam masih mengalami kesulitan dalam membedakan kelas-kelas yang berdekatan, meskipun secara keseluruhan mampu menghasilkan performa yang cukup kompetitif dalam prediksi predikat kelulusan mahasiswa.

d. Evaluasi Kinerja Model DNN Menggunakan Hessian-Free Optimization (HFO)

Evaluasi kinerja model Deep Neural Network (DNN) dengan Hessian-Free Optimization (HFO) dilakukan untuk menilai efektivitas metode optimisasi berbasis *second-order* dalam meningkatkan akurasi dan stabilitas prediksi predikat kelulusan


mahasiswa. Berbeda dengan optimizer berbasis gradien orde pertama, HFO memanfaatkan informasi kelengkungan fungsi loss secara implisit, sehingga diharapkan mampu menghasilkan konvergensi yang lebih stabil dan solusi yang lebih optimal.

Tabel 4. 13 Hasil Evaluasi Model DNN dengan HFO

Metrik	Nilai
Accuracy	0,8564 (85,64%)
Precision (Weighted Avg)	0,8175
Recall (Weighted Avg)	0,8564
F1-Score (Weighted Avg)	0,8358

Tabel 4. 14 Classification Report HFO

Kelas	Precision	Recall	F1-Score	Support
Cukup	0,00	0,00	0,00	5
Memuaskan	0,00	0,00	0,00	60
Sangat Memuaskan	0,84	0,92	0,88	785
Cumlaude	0,89	0,86	0,87	536
Accuracy	-	-	0,86	1386
Macro Average	0,43	0,45	0,44	1386
Weighted Average	0,82	0,86	0,84	1386



Gambar 4. 6 Confusion Matrix - HFO

Berdasarkan hasil pengujian pada 1.386 data uji, model Deep Neural Network (DNN) dengan optimizer Hessian-Free Optimization (HFO) Tabel 4.13 menghasilkan akurasi tertinggi di antara seluruh optimizer yang diuji, yaitu sebesar 85,64%, dengan nilai precision 0,8175, recall 0,8564, dan F1-score 0,8358. Nilai weighted average F1-score sebesar 0,84 menunjukkan bahwa model memiliki performa keseluruhan yang sangat baik dalam memprediksi predikat kelulusan mahasiswa. Dibandingkan dengan SGDM, RMSProp, dan Adam, HFO menunjukkan kemampuan terbaik dalam mengenali data aktual, yang tercermin dari nilai recall dan akurasi tertinggi. Namun demikian, nilai macro average F1-score yang hanya mencapai 0,44 mengindikasikan masih adanya ketimpangan performa yang cukup besar antara kelas mayoritas dan kelas minoritas.

Dari sisi performa per kelas Tabel 4.14, HFO menunjukkan kontras yang sangat jelas antara kelas mayoritas dan minoritas. Pada kelas Cukup (5 data) dan Memuaskan (60 data), model gagal melakukan klasifikasi dengan benar sehingga menghasilkan nilai precision, recall, dan F1-score sebesar 0,00. Seluruh data pada kedua kelas tersebut diprediksi sebagai kelas Sangat Memuaskan. Sebaliknya, pada kelas mayoritas, HFO menunjukkan performa yang sangat baik. Kelas Sangat Memuaskan mencapai precision 0,84, recall 0,92, dan F1-score 0,88, dengan 725 dari 785 data berhasil diklasifikasikan dengan benar. Sementara itu, kelas Cumlaude memperoleh precision 0,89, recall 0,86, dan F1-score 0,87, dengan 462 dari 536 data berhasil diprediksi secara tepat.

Berdasarkan confusion matrix Gambar 4.6, kesalahan klasifikasi terbesar terjadi antara dua kelas mayoritas, yaitu 60 data Sangat Memuaskan diprediksi sebagai

Cumlaude dan 74 data Cumlaude diprediksi sebagai Sangat Memuaskan. Meskipun demikian, jumlah prediksi yang benar pada kedua kelas tersebut tetap sangat dominan dibandingkan kesalahan yang terjadi. Secara keseluruhan, hasil ini menunjukkan bahwa HFO merupakan optimizer dengan performa terbaik dalam penelitian ini, terutama dalam memaksimalkan akurasi dan kemampuan generalisasi pada kelas mayoritas. Namun, ketidakmampuannya dalam mengenali kelas minoritas menunjukkan bahwa masalah class imbalance masih menjadi tantangan utama, sehingga penerapan teknik penyeimbangan data seperti class weighting atau oversampling berpotensi meningkatkan performa model pada penelitian lanjutan.

4.4.3. Ringkasan Komparatif Kinerja Optimizer

Berdasarkan hasil evaluasi pada data uji (1.386 sampel), keempat optimizer menunjukkan perbedaan performa yang signifikan. Tabel 4.15 menyajikan ringkasan komparatif kinerja keempat optimizer berdasarkan metrik akurasi, precision, recall, dan F1-score.

Tabel 4. 15 Komparatif Kinerja Optimizer

Optimizer	Akurasi	Precision	Recall	F1-Score
SGDM	0,8016 (80,16%)	0,8496	0,8016	0,8173
RMSProp	0,8110 (81,10%)	0,8418	0,8110	0,8168
Adam	0,8045 (80,45%)	0,8564	0,8045	0,8205
HFO	0,8564 (85,64%)	0,8175	0,8564	0,8358

Berdasarkan hasil perbandingan kinerja keempat optimizer (SGDM, RMSProp, Adam, dan HFO) pada tugas klasifikasi predikat kelulusan mahasiswa, diperoleh temuan bahwa Hessian-Free Optimization (HFO) menunjukkan performa terbaik

secara keseluruhan. HFO mencapai akurasi tertinggi sebesar 85,64%, recall tertinggi sebesar 0,8564, dan F1-score tertinggi sebesar 0,8358. Keunggulan HFO ini diduga berasal dari kemampuannya memanfaatkan informasi kelengkungan (curvature) fungsi loss melalui pendekatan second-order optimization, sehingga mampu menemukan arah pembaruan parameter yang lebih optimal dibandingkan metode berbasis gradien orde pertama. Meskipun demikian, HFO menghasilkan nilai precision terendah (0,8175) dibandingkan optimizer lainnya. Hal ini menunjukkan bahwa model masih menghasilkan sejumlah false positive, terutama akibat kecenderungan mengklasifikasikan kelas minoritas ke dalam kelas mayoritas. Namun secara keseluruhan, HFO tetap menjadi optimizer terbaik karena mampu menghasilkan keseimbangan performa yang paling baik yang tercermin dari nilai akurasi, recall, dan F1-score tertinggi.

Di antara ketiga optimizer berbasis first-order, RMSProp menghasilkan akurasi tertinggi sebesar 81,10%, diikuti oleh Adam sebesar 80,45% dan SGDM sebesar 80,16%. Dari sisi precision, Adam memperoleh nilai tertinggi sebesar 0,8564, menunjukkan bahwa prediksi yang dihasilkannya cenderung lebih tepat dibandingkan optimizer lainnya. Selain itu, Adam juga menghasilkan F1-score sebesar 0,8205, sedikit lebih tinggi dibandingkan SGDM (0,8173) dan RMSProp (0,8168). Sementara itu, RMSProp tetap unggul dari sisi akurasi dan recall, yang mengindikasikan kemampuan yang lebih baik dalam mengenali data aktual. SGDM menunjukkan performa yang relatif stabil dan dapat digunakan sebagai baseline karena menghasilkan kinerja yang tidak jauh berbeda dengan RMSProp maupun Adam.

Secara keseluruhan, apabila ditinjau berdasarkan akurasi dan recall, urutan performa optimizer adalah HFO, RMSProp, Adam, dan SGDM. Namun apabila ditinjau berdasarkan F1-score, urutannya menjadi HFO, Adam, SGDM, dan RMSProp. Hasil ini menunjukkan bahwa HFO merupakan optimizer yang paling efektif dalam penelitian ini, sedangkan ketiga optimizer first-order memiliki karakteristik keunggulan yang berbeda. Temuan ini memperkuat kontribusi penelitian dalam pengembangan pendekatan optimisasi lanjutan berbasis Deep Neural Network untuk prediksi predikat kelulusan mahasiswa pada bidang Educational Data Mining.

4.5. Studi Ablasi Fitur

Studi ablasi fitur dilakukan untuk menganalisis kontribusi tambahan variabel non-akademik terhadap kinerja model prediksi. Dalam studi ini, dua skenario dibandingkan:

1. Model Akademik + Non-Akademik (telah dibahas pada Subbab 4.4.2.d): menggunakan seluruh 12 variabel (4 IPS + 8 variabel non-akademik) dengan optimizer HFO.
2. Model Akademik : hanya menggunakan 4 variabel IPS (semester 1–4) dengan optimizer HFO.

Kedua model menggunakan optimizer HFO dengan parameter pelatihan yang identik, sehingga perbedaan performa yang dihasilkan dapat diatribusikan secara langsung pada perbedaan komposisi fitur.


4.5.1. Hasil evaluasi Model Akademik

Tabel 4. 16 Hasil Evaluasi Model DNN dengan Optimizer HFO (Model Akademik)

Metrik	Nilai
Accuracy	0,8485 (84,85%)
Precision (Weighted Avg)	0,8091
Recall (Weighted Avg)	0,8485
F1-Score (Weighted Avg)	0,8281

Tabel 4. 17 Classification Report HFO (Model Akademik)

Kelas	Precision	Recall	F1-Score	Support
Cukup	0,00	0,00	0,00	5
Memuaskan	0,00	0,00	0,00	60
Sangat Memuaskan	0,84	0,91	0,87	785
Cumlaude	0,86	0,87	0,87	536
Macro Average	0,43	0,44	0,43	1386
Weighted Average	0,81	0,85	0,83	1386
Accuracy			0,8485 (84,85%)	1386



Gambar 4. 7 Confusion Matrix - HFO Model Akademik

Berdasarkan hasil pengujian pada 1.386 data uji, model *Deep Neural Network* (DNN) dengan optimizer HFO yang hanya memanfaatkan variabel akademik (IPS 1–4) mencapai akurasi sebesar 84,85% dan F1-score tertimbang (*weighted avg*) sebesar 0,83. Capaian ini menunjukkan bahwa Indeks Prestasi Semester (IPS) pada semester awal hingga pertengahan (semester 1–4) merupakan prediktor yang sangat

kuat dalam menentukan predikat kelulusan mahasiswa. Tingginya akurasi yang diperoleh hanya dari keempat nilai IPS mengindikasikan bahwa performa akademik pada fase awal masa studi memiliki korelasi yang erat dengan capaian akhir kelulusan. Dengan demikian, keempat variabel ini sudah cukup memberikan gambaran yang akurat mengenai potensi predikat kelulusan mahasiswa, meskipun masih terdapat ruang untuk peningkatan melalui penambahan variabel non-akademik.

Dari sisi performa per kelas, model mengalami kegagalan total pada kelas minoritas, yaitu Cukup (5 data) dan Memuaskan (60 data), dengan precision, recall, dan F1-score = 0,00. Seluruh data dari kedua kelas tersebut (5 data Cukup dan 60 data Memuaskan) semuanya salah diprediksi sebagai kelas Sangat Memuaskan. Hal ini disebabkan oleh ketidakseimbangan distribusi data yang ekstrem, di mana kelas Cukup hanya mewakili 0,36% dan kelas Memuaskan hanya 4,33% dari total data. Akibatnya, model cenderung mengabaikan kedua kelas minoritas demi meminimalkan nilai *loss* secara global. Kondisi ini menjadi tantangan utama yang harus diatasi sebelum model dapat diimplementasikan secara praktis.

Sebaliknya, pada kelas mayoritas, model menunjukkan performa yang sangat baik. Kelas Sangat Memuaskan (785 data) mencapai *recall* 0,91, *precision* 0,84, dan F1-score 0,87, yang berarti 711 dari 785 data (90,6%) berhasil diklasifikasikan dengan benar. Kelas Cumlaude (536 data) mencapai *recall* 0,87, *precision* 0,86, dan F1-score 0,87, yang berarti 465 dari 536 data (86,8%) berhasil diklasifikasikan dengan benar. Masih terdapat pergeseran prediksi antar kedua kelas mayoritas, yaitu sebanyak 74 data dari kelas Sangat Memuaskan yang salah diprediksi sebagai Cumlaude, dan 71 data dari kelas Cumlaude yang salah diprediksi sebagai Sangat

Memuaskan. Pergeseran ini menunjukkan bahwa batas keputusan (*decision boundary*) antara kedua kelas mayoritas masih cukup tipis, kemungkinan disebabkan oleh rentang IPK yang berdekatan antara predikat Sangat Memuaskan (IPK 3,01–3,50) dan Cumlaude (IPK $\geq 3,51$), sehingga model masih mengalami kesulitan dalam membedakan keduanya secara sempurna.

Model akademik berbasis IPS 1–4 terbukti sangat efektif dalam membedakan dua kelas mayoritas (Sangat Memuaskan dan Cumlaude), dengan tingkat keberhasilan di atas 86% untuk kedua kelas. Namun, model belum cukup sensitif untuk memisahkan kelas dengan capaian akademik lebih rendah (Cukup dan Memuaskan) akibat ketidakseimbangan distribusi data yang ekstrem. Temuan ini menegaskan bahwa meskipun variabel akademik merupakan prediktor dominan, penerapan teknik penanganan ketidakseimbangan kelas (*class imbalance handling*) seperti SMOTE, *cost-sensitive learning*, atau pembobotan kelas (*class weighting*) yang lebih agresif tetap diperlukan agar model mampu mengenali kelas minoritas dengan lebih baik. Selain itu, penambahan variabel non-akademik juga perlu dipertimbangkan untuk membantu memperjelas batas keputusan antara kelas Sangat Memuaskan dan Cumlaude, sehingga model dapat menghasilkan prediksi yang lebih akurat sebelum diimplementasikan secara praktis di lingkungan perguruan tinggi.

4.5.2. Hasil Studi Ablasi Fitur

Tabel 4. 18 Komparatif Evaluasi Model Akademik dan Model Akademik + Non Akademik

Variable	Accuracy	Precision	Recall	F1-Score
HFO Akademik	0,8485 (84,85%)	0,8091	0,8485	0,8281
HFO Akademik + Non Akademik	0,8564 (85,64%)	0,8175	0,8564	0,8358
Peningkatan	+0,0079 (+0,79%)	+0,0084	+0,0079	+0,0077

Berdasarkan hasil studi ablasi fitur, penambahan variabel non-akademik memberikan peningkatan performa pada seluruh metrik evaluasi. Model dengan kombinasi fitur akademik dan non-akademik mencapai akurasi 85,64% dan F1-score 0,8358, lebih tinggi dibandingkan model yang hanya menggunakan variabel akademik saja (84,85% dan 0,8281), dengan peningkatan akurasi sebesar 0,79%. Capaian ini menunjukkan bahwa variabel non-akademik seperti jenis kelamin, asal sekolah, pengalaman mondok, jalur PMB, kemampuan bahasa Arab, kemampuan bahasa Inggris, kemampuan komputer, dan jurusan memberikan kontribusi komplementer yang bermakna dalam meningkatkan kinerja model prediksi predikat kelulusan mahasiswa.

Dari sisi performa per kelas, kedua model menunjukkan pola yang sama, yaitu gagal total pada kelas minoritas (Cukup dan Memuaskan) akibat ketidakseimbangan distribusi data yang ekstrem. Namun, pada kelas mayoritas, model kombinasi fitur menunjukkan peningkatan yang lebih baik dibandingkan model akademik saja. Temuan ini menegaskan bahwa prediksi predikat kelulusan mahasiswa akan lebih akurat jika tidak hanya berdasarkan nilai IPS, tetapi juga mempertimbangkan informasi kontekstual seperti latar belakang pendidikan dan kemampuan bahasa. Model dengan

kombinasi fitur akademik dan non-akademik direkomendasikan untuk implementasi, meskipun tetap memerlukan penanganan ketidakseimbangan kelas agar model mampu mengenali kelas minoritas dengan lebih baik.

BAB V PEMBAHASAN

5.1. Pembahasan Hasil Evaluasi Model Prediksi Predikat Kelulusan

Hasil evaluasi pada 1.386 data uji menunjukkan bahwa model Deep Neural Network (DNN) mampu memprediksi predikat kelulusan mahasiswa dengan tingkat akurasi yang bervariasi tergantung pada algoritma optimisasi yang digunakan. Secara umum, seluruh model menunjukkan kemampuan yang lebih baik pada kelas mayoritas (*Sangat Memuaskan* dan *Cumlaude*) dibandingkan kelas minoritas (*Cukup* dan *Memuaskan*). Hal ini mengindikasikan bahwa distribusi data yang tidak seimbang (*imbalanced data*) menjadi tantangan utama dalam tugas klasifikasi multikelas pada domain pendidikan.

5.1.1. Keunggulan HFO dalam Akurasi Global dan Konvergensi

Hessian-Free Optimization (HFO) menunjukkan performa terbaik secara global dibandingkan ketiga *optimizer* lainnya, dengan akurasi 85,64% dan *weighted F1-score* 0,8358. Capaian ini unggul dibandingkan SGD+Momentum (akurasi 80,16%, F1-score 0,8173), RMSProp (akurasi 81,10%, F1-score 0,8168), dan Adam (akurasi 80,45%, F1-score 0,8205). Keunggulan ini dapat dijelaskan dari perspektif teori optimisasi. Berbeda dengan metode *first-order* yang hanya memanfaatkan informasi gradien, HFO memanfaatkan informasi kelengkungan (*curvature*) fungsi *loss* melalui matriks Hessian (tanpa membentuknya secara eksplisit). Informasi kelengkungan ini memungkinkan HFO untuk: (1) menemukan arah pencarian yang lebih informatif dibandingkan metode gradien murni, (2) mengurangi risiko *oscillation* dan *slow*

convergence yang sering terjadi pada metode *first-order*, dan (3) beradaptasi terhadap bentuk fungsi *loss* lokal melalui mekanisme *damping* dan *line search*.

Keunggulan teoretis ini terbukti secara empiris dari hasil konvergensi antar *optimizer*. HFO mencapai titik konvergensi paling cepat, yaitu pada epoch ke-61, jauh lebih cepat dibandingkan RMSProp (epoch 360), Adam (epoch 380), dan SGD+Momentum (epoch 523). Perbedaan kecepatan konvergensi ini sangat signifikan—HFO konvergen hampir 6 kali lebih cepat dibandingkan metode *first-order* terbaik kedua (RMSProp). Selain itu, HFO juga mencatatkan akurasi pelatihan tertinggi (86,41%) dan akurasi validasi tertinggi (83,62%) di antara semua *optimizer*. Yang terpenting, selisih antara akurasi pelatihan dan validasi pada HFO hanya 2,79% (86,41% - 83,62%), merupakan selisih terkecil dibandingkan SGD+Momentum (7,92%), RMSProp (8,69%), dan Adam (6,40%). Hal ini mengindikasikan bahwa HFO tidak hanya konvergen lebih cepat, tetapi juga memiliki kemampuan generalisasi yang sangat baik tanpa indikasi *overfitting* yang berarti. Kurva konvergensi HFO yang stabil dengan penurunan *loss* yang mulus semakin memperkuat bukti bahwa pemanfaatan informasi kelengkungan secara efektif membantu model menemukan optimum yang lebih baik dan lebih cepat dibandingkan metode gradien murni.

5.1.2. Kelemahan HFO pada Kelas Minoritas (Class Imbalance)

Meskipun HFO unggul dalam akurasi global (85,64%) dan kecepatan konvergensi, metode ini mengalami kegagalan total dalam mengklasifikasikan kelas minoritas, yaitu Cukup (5 data) dan Memuaskan (60 data), dengan *precision*, *recall*,

dan F1-score = 0,00. Seluruh data dari kedua kelas ini (5 data Cukup dan 60 data Memuaskan) seluruhnya salah diprediksi sebagai kelas Sangat Memuaskan, yang disebabkan oleh ketidakseimbangan distribusi data yang ekstrem—kelas Cukup hanya 0,36% dan Memuaskan hanya 4,33% dari total data uji. Dalam kondisi seperti ini, model DNN cenderung mengabaikan kelas minoritas karena meminimalkan *loss* secara global lebih mudah dicapai dengan memprediksi kelas mayoritas dengan benar, sesuai dengan literatur *class imbalance* yang menyatakan bahwa standar *cross-entropy loss* akan didominasi oleh kelas dengan jumlah sampel terbanyak (He & Garcia, 2009). Penambahan variabel non-akademik ternyata belum cukup mengatasi masalah ini, sehingga diperlukan teknik penanganan ketidakseimbangan kelas seperti SMOTE, *cost-sensitive learning*, atau pembobotan kelas yang lebih agresif sebelum model dapat diimplementasikan secara praktis.

5.2. Pembahasan Perbandingan Kinerja Optimizer

5.2.1. First-Order Optimizers sebagai Baseline (SGDM, RMSProp, Adam)

Ketiga algoritma *first-order* (SGD+Momentum, RMSProp, dan Adam) berfungsi sebagai metode pembandingan (*baseline*) dalam penelitian ini. SGD+Momentum menghasilkan performa terendah di antara ketiga *baseline* dengan akurasi 80,16% dan F1-score 0,8173, serta memerlukan waktu konvergensi paling lama hingga epoch ke-523. Rendahnya performa SGD+Momentum dapat dijelaskan oleh ketergantungan pada *learning rate* tetap yang tidak beradaptasi terhadap karakteristik data, serta rentan terhadap *local minima* dan *saddle points*. RMSProp dan Adam menunjukkan peningkatan performa dibandingkan SGD+Momentum, dengan

akurasi masing-masing 81,10% dan 80,45%, serta waktu konvergensi yang jauh lebih cepat (epoch 360 dan 380). Peningkatan ini disebabkan oleh mekanisme *adaptive learning rate* yang memungkinkan setiap parameter memiliki *learning rate* sendiri, sehingga lebih responsif terhadap variasi gradien pada setiap dimensi. Dalam penelitian ini, RMSProp (81,10%; F1-score 0,8168) sedikit mengungguli Adam (80,45%; F1-score 0,8205), yang dapat dijelaskan oleh karakteristik data yang relatif stabil dan tidak terlalu *noisy*, sehingga mekanisme momentum pada Adam tidak memberikan keuntungan tambahan yang signifikan dibandingkan RMSProp.

5.2.2. HFO sebagai Second-Order Optimization (Metode yang Diusulkan)

Berbeda dengan ketiga *baseline* di atas, HFO adalah metode *second-order* yang diusulkan dalam penelitian ini dan terbukti menjadi *optimizer* terbaik secara keseluruhan dengan akurasi **85,64%**, F1-score **0,8358**, serta waktu konvergensi paling cepat pada **epoch ke-61**—hampir 6 kali lebih cepat dibandingkan RMSProp. Keunggulan HFO dibandingkan metode *first-order* dapat dijelaskan dari perspektif teori optimisasi, di mana arah Newton ($d = -H^{-1}g$) secara teoritis lebih optimal dibandingkan arah gradien karena memanfaatkan informasi kelengkungan fungsi *loss* untuk menemukan arah pencarian yang lebih langsung menuju optimum. HFO mengatasi masalah komputasi metode Newton konvensional dengan: (1) tidak pernah membentuk matriks Hessian secara eksplisit, (2) menghitung *Hessian-vector product* dengan biaya $O(p)$ menggunakan identitas Pearlmutter (1994), dan (3) menyelesaikan sistem $(H + \lambda I)d = -g$ secara iteratif menggunakan *Conjugate Gradient*. Hasilnya adalah arah pencarian yang secara teoritis lebih optimal, yang tercermin dari akurasi dan F1-score HFO yang tertinggi di antara semua *optimizer*, serta kurva

konvergensi yang paling stabil dengan selisih akurasi pelatihan dan validasi terkecil (2,79%), mengindikasikan kemampuan generalisasi yang sangat baik.

5.3. Pembahasan Studi Ablasi Fitur

5.3.1. Variabel Akademik sebagai Prediktor Dominan

Model yang hanya menggunakan variabel akademik (IPS 1–4) mencapai akurasi 84,85% dan F1-score 0,8281. Capaian ini menunjukkan bahwa IPS pada semester awal hingga pertengahan merupakan prediktor yang sangat kuat untuk menentukan predikat kelulusan mahasiswa. Temuan ini konsisten dengan penelitian terdahulu yang menyatakan bahwa kinerja di mata kuliah tahun-tahun awal memiliki korelasi kuat dengan keberhasilan akhir studi mahasiswa (Wibowo & Rohman, 2022; Widaningsih, 2019). IPS semester 3 dan 4 memiliki korelasi tertinggi (0,61) dibanding IPS semester 1 dan 2 (0,56), mengindikasikan bahwa performa akademik pada pertengahan masa studi semakin penting dalam menentukan capaian akhir.

5.3.2. Kontribusi Komplementer Variabel Non-Akademik

Penambahan variabel non-akademik meningkatkan akurasi sebesar 0,79% (dari 84,85% menjadi 85,64%) dan F1-score sebesar 0,0077 (dari 0,8281 menjadi 0,8358). Peningkatan ini menunjukkan bahwa variabel non-akademik seperti jenis kelamin, asal sekolah, pengalaman mondok, jalur PMB, kemampuan bahasa Arab, kemampuan bahasa Inggris, kemampuan komputer, dan jurusan memberikan kontribusi komplementer yang bermakna dalam meningkatkan kinerja model. Temuan ini memiliki signifikansi praktis yang penting, terutama dalam konteks penerimaan

mahasiswa baru di mana data IPS semester belum tersedia, variabel non-akademik dapat digunakan untuk *screening* awal mahasiswa yang berpotensi berisiko.

Variabel non-akademik yang paling berpengaruh berdasarkan analisis korelasi adalah Jurusan Teknik Informatika (korelasi 0,14) dan Jenis Kelamin Perempuan (0,14). Menariknya, pengalaman mondok menunjukkan korelasi negatif kecil (-0,09 untuk "Pernah Mondok (Ya)"), yang perlu dikaji lebih lanjut dalam konteks perguruan tinggi Islam.

5.4. Implikasi Penelitian

Implikasi Akademik: Penelitian ini memberikan kontribusi metodologis melalui implementasi HFO pada domain *Educational Data Mining*, kontribusi empiris melalui pembuktian bahwa HFO mengungguli SGDM, RMSProp, dan Adam, serta kontribusi kontekstual melalui integrasi variabel khas perguruan tinggi Islam.

Implikasi Praktis: Model yang dikembangkan dapat dimanfaatkan sebagai sistem pendukung keputusan untuk mengidentifikasi potensi predikat kelulusan mahasiswa sejak semester 4, menyusun strategi pembinaan berbasis data, dan mengoptimalkan alokasi sumber daya pembinaan akademik. Namun, model ini tidak boleh digunakan sebagai alat pelabelan final, melainkan sebagai alat bantu intervensi dini.

5.5. Integrasi Sains dan Islam dalam Pengembangan Model Prediksi

5.5.1. Dasar Teologis Pengembangan Ilmu

Penelitian ini tidak hanya dipahami sebagai kajian teknis komputasional, tetapi juga sebagai bagian dari paradigma integrasi sains dan Islam yang menjadi fondasi

akademik perguruan tinggi Islam. Allah SWT berfirman dalam QS. Al-Mujadilah ayat 11 yang artinya:

"Allah akan meninggikan orang-orang yang beriman di antara kamu dan orang-orang yang diberi ilmu beberapa derajat."

Ayat ini menunjukkan bahwa pengembangan ilmu bukan sekadar aktivitas intelektual, tetapi sarana peningkatan kualitas manusia secara spiritual dan sosial. Dalam konteks penelitian ini, pengembangan model prediksi berbasis DNN dan HFO adalah bentuk aktualisasi perintah menuntut ilmu (QS. Al-'Alaq: 1-5) yang mengintegrasikan wahyu, akal, dan realitas empiris.

5.5.2. Etika Data dan Keadilan Model (Fairness)

Islam memandang manusia sebagai khalifah fil ardh (QS. Al-Baqarah: 30) yang memikul amanah dalam mengelola sumber daya, termasuk data. Dalam pengembangan model prediksi, prinsip etika yang harus dijaga meliputi:

1. Kerahasiaan data (al-sirriyyah): Data mahasiswa bersifat sensitif dan dilindungi. Penelitian ini menggunakan data agregat anonim, dan akses data dilakukan dengan persetujuan pihak berwenang.
2. Keadilan (al-'adl): Model tidak boleh bias terhadap kelompok tertentu. Temuan bahwa HFO gagal pada kelas minoritas menunjukkan bahwa belum ada keadilan algoritmik dalam model ini. Ini menjadi peringatan bahwa model prediksi tidak boleh diimplementasikan tanpa penanganan *class imbalance* terlebih dahulu.

3. Transparansi (al-shafafiyyah): Seluruh parameter, arsitektur, dan implementasi HFO telah dijelaskan secara transparan dalam Bab III, sehingga dapat direview dan direplikasi.
4. Kemaslahatan (al-maslahah): Model ini dikembangkan untuk kemaslahatan umat, yaitu membantu institusi pendidikan dalam melakukan intervensi akademik dini. Namun, model tidak boleh digunakan untuk memarginalkan atau mendiskriminasi mahasiswa tertentu.

5.5.3. Prediksi sebagai Alat Bantu, Bukan Pelabelan Final

Dalam paradigma Islam, manusia memiliki potensi untuk berubah dan bertumbuh (*tathawwur*). Hasil prediksi model hanyalah estimasi probabilitas berdasarkan data historis, bukan takdir atau keputusan final. Sebagaimana sabda Nabi SAW:

"Sesungguhnya dunia itu terlaknat, dan terlaknat pula apa yang ada di dalamnya, kecuali zikir kepada Allah dan apa-apa yang mendekatinya, serta orang alim dan orang yang belajar." (HR. Tirmidzi)

Hadis ini mengingatkan bahwa ilmu harus diarahkan untuk kebaikan, bukan untuk mengecap atau melabeli seseorang secara permanen. Oleh karena itu, implementasi model prediksi di lingkungan pendidikan harus disertai dengan:

- Mekanisme banding bagi mahasiswa yang diprediksi berisiko
- Intervensi yang membangun, bukan menghukum
- Evaluasi berkala untuk memperbaiki bias model

Dengan demikian, penelitian ini merepresentasikan sintesis antara metodologi ilmiah modern di bidang kecerdasan buatan dan nilai-nilai Islam yang menekankan kesatuan ilmu, etika data, dan tanggung jawab moral.

5.6. Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan yang perlu diakui. Pertama, ketidakseimbangan distribusi data (*class imbalance*) yang ekstrem menjadi keterbatasan paling signifikan, di mana kelas minoritas (Cukup hanya 0,36% dan Memuaskan hanya 4,33% dari total data uji) menyebabkan model gagal mengklasifikasikan kedua kelas tersebut dengan precision, recall, dan F1-score = 0,00. Penelitian lanjutan perlu menerapkan teknik penanganan *class imbalance* seperti SMOTE, *class weighting* yang lebih agresif, atau *cost-sensitive learning* agar model mampu mengenali pola pada kelas minoritas secara lebih baik. Kedua, data yang digunakan dalam penelitian ini hanya berasal dari satu institusi, yaitu alumni Fakultas Sains dan Teknologi UIN Maulana Malik Ibrahim Malang, sehingga hasil penelitian mungkin tidak langsung dapat digeneralisasikan ke fakultas lain atau perguruan tinggi lain tanpa pengujian lebih lanjut pada dataset yang beragam. Ketiga, variabel non-akademik yang digunakan dalam penelitian ini masih terbatas pada data yang tersedia di SIAKAD, sehingga belum mencakup faktor-faktor psikologis, motivasi belajar, dukungan keluarga, kondisi sosial-ekonomi, atau variabel non-akademik lain yang lebih mendetail yang mungkin turut mempengaruhi predikat kelulusan mahasiswa. Keempat, model yang dihasilkan belum diuji pada dataset dari institusi lain (*external validation*), sehingga kemampuan generalisasi (*generalizability*) model

masih perlu dikonfirmasi lebih lanjut sebelum dapat diterapkan secara luas di lingkungan perguruan tinggi yang berbeda.

BAB VI KESIMPULAN DAN SARAN

6.1. Kesimpulan

Berdasarkan hasil penelitian mengenai penerapan *Deep Neural Network* (DNN) untuk prediksi predikat kelulusan mahasiswa dengan berbagai metode optimisasi, dapat ditarik beberapa kesimpulan sebagai berikut:

1. Model DNN mampu memprediksi predikat kelulusan mahasiswa dengan performa yang baik, khususnya pada kelas mayoritas (Sangat Memuaskan dan Cumlaude). Hal ini menunjukkan bahwa pendekatan *deep learning* efektif dalam menangkap pola kompleks dari data akademik dan non-akademik mahasiswa, dengan tingkat keberhasilan klasifikasi di atas 86% untuk kedua kelas mayoritas.
2. Pemilihan *optimizer* berpengaruh signifikan terhadap kinerja model. Berdasarkan hasil evaluasi pada 1.386 data uji diperoleh:
 - a. SGD+Momentum : akurasi 80,16% (F1-score 0,8173), konvergensi pada epoch 523
 - b. RMSProp : akurasi 81,10% (F1-score 0,8168), konvergensi pada epoch 360
 - c. Adam : akurasi 80,45% (F1-score 0,8205), konvergensi pada epoch 380
 - d. HFO : akurasi 85,64% (F1-score 0,8358), konvergensi pada epoch 61

Hasil ini menunjukkan bahwa metode *adaptive first-order* (RMSProp dan Adam) secara signifikan meningkatkan performa dan kecepatan konvergensi dibandingkan *first-order* konvensional (SGD+Momentum), sedangkan

metode *second-order* (HFO) menghasilkan performa terbaik secara keseluruhan dengan konvergensi hampir 6 kali lebih cepat dibandingkan RMSProp.

3. Hessian-Free Optimization (HFO) merupakan *optimizer* paling efektif dalam penelitian ini. HFO mencapai akurasi tertinggi (85,64%), F1-score tertinggi (0,8358), akurasi pelatihan tertinggi (86,41%), akurasi validasi tertinggi (83,62%), serta konvergensi paling cepat (epoch ke-61). Pemanfaatan informasi kurvatur fungsi *loss* melalui pendekatan *second-order* mampu meningkatkan kualitas konvergensi dan generalisasi model, yang tercermin dari selisih akurasi pelatihan dan validasi terkecil (2,79%). Namun demikian, HFO memiliki kelemahan signifikan dalam memprediksi kelas minoritas (Cukup dan Memuaskan) akibat ketidakseimbangan distribusi data yang ekstrem—kelas Cukup hanya 0,36% dan Memuaskan 4,33% dari total data uji, sehingga seluruh data kedua kelas tersebut salah diprediksi sebagai kelas Sangat Memuaskan.
4. Variabel akademik (IPS semester 1–4) merupakan faktor dominan dalam prediksi predikat kelulusan. Model yang hanya menggunakan variabel akademik mencapai akurasi 84,85% dengan F1-score 0,8281. Hal ini menunjukkan bahwa capaian akademik pada semester awal hingga pertengahan memiliki korelasi yang sangat kuat terhadap predikat kelulusan, sehingga keempat variabel IPS awal sudah cukup memberikan gambaran yang akurat tentang potensi kelulusan mahasiswa.

5. Kombinasi variabel akademik dan non-akademik meningkatkan stabilitas prediksi model. Penggabungan variabel menghasilkan peningkatan akurasi sebesar 0,79% (dari 84,85% menjadi 85,64%) dan peningkatan F1-score sebesar 0,0077 (dari 0,8281 menjadi 0,8358). Selain itu, penambahan variabel non-akademik berhasil mengurangi kesalahan klasifikasi antar kelas mayoritas, yaitu pada kelas Sangat Memuaskan yang salah diprediksi sebagai Cumlaude turun dari 74 menjadi 60 data. Variabel non-akademik terbukti memberikan kontribusi komplementer yang bermakna, terutama dalam memperjelas *decision boundary* antara kedua kelas mayoritas yang memiliki rentang IPK berdekatan.

Secara keseluruhan, penelitian ini memberikan tiga kontribusi signifikan: (1) kontribusi metodologis melalui implementasi HFO pada domain *Educational Data Mining*, (2) kontribusi empiris melalui pembuktian bahwa HFO mengungguli SGD+Momentum, RMSProp, dan Adam dalam akurasi global, F1-score, dan kecepatan konvergensi, serta (3) kontribusi kontekstual melalui integrasi variabel khas perguruan tinggi Islam (pengalaman mondok, kemampuan bahasa Arab) dalam model prediksi berbasis DNN.

6.2. Saran

Berdasarkan hasil penelitian dan keterbatasan yang telah diidentifikasi, beberapa saran untuk penelitian selanjutnya adalah sebagai berikut:

1. Penerapan teknik penanganan class imbalance, seperti:
 - Oversampling (SMOTE)
 - Undersampling
 - Cost-sensitive learning untuk meningkatkan performa pada kelas minoritas.
2. Penambahan variabel non-akademik yang lebih komprehensif, seperti:
 - Faktor psikologis (motivasi, self-regulated learning)
 - Faktor sosial-ekonomi
 - Pola kehadiran dan aktivitas pembelajaran digital
3. Eksplorasi metode optimisasi lanjutan atau hybrid optimization, misalnya kombinasi adaptive first-order dengan pendekatan second-order untuk memperoleh keseimbangan antara efisiensi komputasi dan kualitas konvergensi.
4. Pengujian model pada dataset lintas institusi, untuk menguji robustnes dan kemampuan generalisasi model dalam skala yang lebih luas.
5. Pengembangan sistem prediksi berbasis dashboard interaktif, sehingga hasil penelitian dapat diimplementasikan secara langsung sebagai sistem pendukung keputusan di lingkungan perguruan tinggi.

DAFTAR PUSTAKA

- Alturki et al. (2021). *Uoc Tfg - E Ducational D Ata M Ining &. 5(3)*, 53–73.
- Baker, R. S. J. D., & Yacef, K. (2009). The State of Educational Data Mining in 2009 : A Review and Future Visions. *Journal of Educational Data Mining*, 1(1), 3–16.
- Defazio, A., & Bottou, L. (2019). On the ineffectiveness of variance reduced optimization for deep learning. *Advances in Neural Information Processing Systems*, 32(NeurIPS).
- Delong, L., & Kozak, A. (2023). *The use of autoencoders for training neural networks with mixed categorical and numerical features.* 213–232. <https://doi.org/10.1017/asb.2023.15>
- Geron, A. (2019). *Hands-On_Appendix_Edition.*
- Goodfellow and Yoshua Bengio. (2016). Deep learning. In *MIT Press* (Vol. 29, Nomor 7553). <http://deeplearning.net/>
- Guntara, M. (2025). *Komparasi Kinerja Label-Encoding dengan One-Hot-Encoding pada Algoritma K-Nearest Neighbor menggunakan Himpunan Data Campuran* *Performance Comparison of Label-Encoding with One-Hot-Encoding Methode on K-Nearest Neighbor Algorithm with Mixed Type Data Set.* 2, 352–360. <https://doi.org/10.26798/jiko.v9i2.1605>
- Indahyanti, U., Azizah, N. L., & Setiawan, H. (2022). Pendekatan Ensemble Learning Untuk Meningkatkan Akurasi Prediksi Kinerja Akademik Mahasiswa. *Jurnal Sains dan Informatika*, 8(2), 160–169. <https://doi.org/10.34128/jsi.v8i2.459>
- Kraus, M., & Feuerriegel, S. (n.d.). *Decision support from financial disclosures with deep neural networks and transfer learning.*
- Martens, J. (2010). Deep learning via Hessian-free optimization. *ICML 2010 - Proceedings, 27th International Conference on Machine Learning*, 735–742.
- Mustakim, & Oktaviani F, G. (2016). *Algoritma K-Nearest Neighbor Classification Sebagai Sistem Prediksi Predikat Prestasi Mahasiswa.* 13(2), 195–202.
- Nasution, N. B., Hartanto, D., Silitonga, D. J., Lasimin, & Mardhiyana, D. (2023). Prediksi Lama Studi dan Predikat Kelulusan Mahasiswa Menggunakan Algoritma Supervised Learning. *G-Tech: Jurnal Teknologi Terapan*, 7(2), 386–395. <https://doi.org/10.33379/gtech.v7i2.2077>
- Nurrohmat, M. A. (2015). Aplikasi Pemrediksi Masa Studi dan Predikat Kelulusan

Mahasiswa Informatika Universitas Muhammadiyah Surakarta Menggunakan Metode Naive Bayes. *Khazanah Informatika: Jurnal Ilmu Komputer dan Informatika*, 1(1), 29–34. <https://doi.org/10.23917/khif.v1i1.1179>

Ofori, F., Maina, E., & Gitonga, R. (2020). Using Machine Learning Algorithms to Predict Students' Performance and Improve Learning Outcome: A Literature Based Review. *Journal of Information and Technology*, 4(1), 2616–3573. <https://stratfordjournals.org/journals/index.php/Journal-of-Information-and-Techn/article/view/480>

Pearlmutter, B. A. (1994). *Fast Exact Multiplication by the Hessian*. *Neural Computation*, 6(1), 147–160.

Potdar, K. (2017). *A Comparative Study of Categorical Variable Encoding Techniques for Neural Network Classifiers*. 175(4), 7–9.

Romero, C., & Ventura, S. (2010). Educational data mining: A review of the state of the art. *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, 40(6), 601–618. <https://doi.org/10.1109/TSMCC.2010.2053532>

Rudy Hendrawan, I. N., Budhi Saputra, I. M. A., Cahya Dewi, G. A. P., Adi Pranata, I. G. S., & Wedasari, N. L. N. (2022). Klasifikasi Lama Studi dan Predikat Kelulusan Mahasiswa menggunakan Metode Naïve Bayes. *Jurnal Eksplora Informatika*, 11(1), 50–56. <https://doi.org/10.30864/eksplora.v11i1.606>

Shahiri, A. M., Husain, W., & Rashid, N. A. (2015). A Review on Predicting Student's Performance Using Data Mining Techniques. *Procedia Computer Science*, 72, 414–422. <https://doi.org/10.1016/j.procs.2015.12.157>

Subarkah, A. A. N. F. (2023). *Prediksi kelulusan mahasiswa berbasis klasifikasi data mining thesis*.

Suleman, A. R., & Palupi, I. (2023). Penerapan Artificial Neural Network (ANN) untuk Prediksi Prestasi Akhir Mahasiswa Melalui Nilai Mata Kuliah Dasar Tingkat 1. *eProceedings ...*, 10(2), 1849–1859. <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/20032%0Ahttps://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/20032/19397>

UIN Malang. (2024). *Pendidikan 2024* (Nomor 50).

Wibowo, A., & Rohman, A. (2022). Prediksi Predikat Kelulusan Mahasiswa Menggunakan Naive Bayes dan Decision Tree pada Universitas XYZ. *EXPERT: Jurnal Manajemen Sistem Informasi dan Teknologi*, 12(2), 104. <https://doi.org/10.36448/expert.v12i2.2810>

- Widaningsih, S. (2019). Perbandingan Metode Data Mining Untuk Prediksi Nilai Dan Waktu Kelulusan Mahasiswa Prodi Teknik Informatika Dengan Algoritma C4,5, Naïve Bayes, Knn Dan Svm. *Jurnal Tekno Insentif*, 13(1), 16–25. <https://doi.org/10.36787/jti.v13i1.78>
- Yaacob, W. F. W., Nasir, S. A. M., Yaacob, W. F. W., & Sobri, N. M. (2019). Supervised data mining approach for predicting student performance. *Indonesian Journal of Electrical Engineering and Computer Science*, 16(3), 1584–1592. <https://doi.org/10.11591/ijeecs.v16.i3.pp1584-1592>
- Yann Lecun, Yoshua Bengio, G. H. (2016). Deep learning 简介 一 、 什么是 Deep Learning ? . *Nature*, 29(7553), 1–73. <http://deeplearning.net/>
- Zulfiqar, L. O. M., Renaningtias, N., & Fathoni, M. Y. (2020). *Educational Data Mining in Graduation Rate and Grade Predictions Utilizing Hybrid Decision Tree and Naïve Bayes Classifier* (hal. 151–157). <https://doi.org/10.5220/0009907101510157>

LAMPIRAN