SKRIPSI

PREDIKSI PENURUNAN MOTIVASI BELAJAR PADA PENGGUNA MOODLE MENGGUNAKAN *MULTILAYER PERCEPTRON* (MLP)

DISUSUN OLEH

FEBRINA SUSMITA RANI

2209020220

PROGRAM STUDI TEKNOLOGI INFORMASI

FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI

UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

MEDAN

2026

PREDIKSI PENURUNAN MOTIVASI BELAJAR PADA PENGGUNA MOODLE MENGGUNAKAN *MULTILAYER PERCEPTRON* (MLP)

SKRIPSI

Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer (S.Kom) dalam Program Studi Tenologi Informasi. Pada Fakultas Ilmu Komputer dan Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara

FEBRINA SUSMITA RANI
2209020220

PROGRAM STUDI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
MEDAN
2026

LEMBAR PENGESAHAN

Judul Skripsi	:	Prediksi Penurunan Motivasi Belajar Pada Pengguna Moodle Menggunakan *Multilayer Perceptron* (MLP)
Nama Mahasiswa	:	Febrina Susmita Rani
NPM	:	2209020220
Program Studi	:	Teknologi Informasi

Menyetujui

Komisi Pembimbing

(Zuli Agustina Gultom,M.Si.)

NIDN. 0130089003

Ketua Program Studi

Fatma Sari Hutagalung, S.Kom, M.Kom

NIDN. 0117019301

Dekan

(Dr. Al-Khowarizmi, S.Kom., M.Kom.)

NIDN. 0127099201

PERNYATAAN ORISINALITAS

PREDIKSI PENURUNAN MOTIVASI BELAJAR PADA PENGGUNA MOODLE MENGGUNAKAN *MULTILAYER PERCEPTRON* (MLP)

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, Juni 2026

Yang membuat pernyataan



Febrina Susmita Rani

NPM. 2209020220

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH
UNTUK KEPENTINGAN
AKADEMIS

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama	: Febrina Susmita Rani
NPM	2209020220
Program Studi	: Teknologi Informasi
Karya Ilmiah	: Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bedas Royalti Non-Eksekutif *(Non-Exclusive Royalty free Right)* atas penelitian skripsi saya yang berjudul:

PREDIKSI PENURUNAN MOTIVASI BELAJAR PADA PENGGUNA MOODLE MENGGUNAKAN *MULTILAYER PERCEPTRON* (MLP)

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non-Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, Juni 2026
Yang membuat pernyataan



Febrina Susmita Rani
NPM. 2209020220

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap	: Febrina Susmita Rani
Tempat dan Tanggal Lahir	: Tangerang, 07 Februari 2004
Alamat Rumah	: JL. Rawa Cangkuk I
Telepon/Faks/HP	081362205154
E-mail	: febriyana30092019@gmail.com
Instansi Tempat Kerja	: -
Alamat Kantor	: -

DATA PENDIDIKAN

SD	: Swasta Muhammadiyah 01	TAMAT: 2015
SMP	: Swasta An-Nizam	TAMAT: 2018
SMA	: Swasta Al-Ulum	TAMAT: 2021

KATA PENGANTAR



Pendahuluan

Puji syukur kehadirat Allah SWT atas segala rahmat dan kurunianya sehingga penulis dapat menyelesaikan skripsi ini yang berjudul "Prediksi Penurunan Motivasi Belajar Pada Pengguna Moodle Menggunakan Multilayer Perceptron (MLP)". Penulis menyampaikan berterima kasih kepada berbagai pihak atas dukungan serta doa dalam proses penyelesaian skripsi. Penulis juga mengucapkan terima kasih kepada:

1. Bapak Prof. Dr. Akrim, M.Pd., Rektor Universitas Muhammadiyah Sumatera Utara (UMSU).
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom. Dekan Fakultas Ilmu Komputer dan Teknologi Informasi (FIKTI) UMSU.
3. Ibu Dr. Firahmi Rizky, S.Kom., M.Kom. Wakil Dekan I Fakultas Ilmu Komputer dan Teknologi Informasi
4. Bapak Mhd. Basri, S.Si, M.Kom**.** Wakil Dekan III Wakil Dekan III Fakultas Ilmu Komputer dan Teknologi Informasi.
5. Ibu Fatma Sari Hutagalung, S.Kom., M.Kom. Ketua Program Studi Teknologi Informasi.
6. Bapak Okvi Nugroho, S.Kom., M.Kom. Sekretaris Program Studi Teknologi Informasi.
7. Ibu Zuli Agustina Gultom, M.Si. Selaku Dosen Pembimbing Skripsi Penulis

Terimakasih atas bimbingan, arahan, dan dukungan yang telah diberikan selama proses penyusunan skripsi ini sehingga dapat diselesaikan dengan baik.

8. Penulis mengucapkan terima kasih sebesar-besarnya kepada kedua orang tua tercinta atas doa, dukungan, kasih sayang tiada henti. Setiap lelah yang penulis rasakan terasa lebih ringan karena adanya semangat dan kepercayaan dari ayah dan mamak. Karya ini penulis persembahkan sebagai bentuk rasa hormat dan terima kasih yang mendalam.
9. Penulis juga mengucapkan terima kasih kepada alm. kakek tercinta yang semasa hidupnya selalu memberikan kasih sayang, doa, dan semangat kepada penulis. Walaupun kakek sudah tidak bersama kami lagi, kenangan dan nasehat akan selalu penulis ingat serta menjadi penyemangat dalam menjalani kehidupan.
10. Tasya dan Luvi yang menjadi sahabat penulis sejak masa perkuliahan. Segala canda, tawa, suka, sedih, dan diskusi larut malam menjadi bagian dari perjuangan yang tidak terasa sendiri. Bersama kalian, hari-hari di kampus berubah menjadi cerita yang layak dikenang. Penulis merasa bersyukur dipertemukan oleh orang yang tulus, setia, dan ceria seperti kalian. Terima kasih telah bertahan di sisi penulis di kala banyak masalah yang dihadapi bersama. Kalian bukan sekedar teman, tapi bagian dari perjalanan yang akan selalu hidup dalam ingatan penulis.
11. Semua pihak yang tidak dapat disebutkan satu persatu yang telah banyak membantu memberikan pemikiran demi kelancaran dan keberhasilan penyusunan skripsi ini.

12. Dan yang terakhir untuk diri saya sendiri, Febrina Susmita Rani. Terima kasih sudah bertahan sejauh ini. Untuk malam-malam penuh tekanan dan air mata terimakasih karena tetap memilih melangkah meski jalan tidak selalu ramah. Kini telah sampai, maka berbahagialah dimanapun berada. Apresiasi sebesar-besarnya karena telah bertanggung jawab untuk menyelesaikan apa yang telah dimulai. Dengan kurang dan lebihmu mari merayakan keberanianmu itu.

PREDIKSI PENURUNAN MOTIVASI BELAJAR PADA PENGGUNA MOODLE MENGGUNAKAN *MULTILAYER PERCEPTRON* (MLP)

ABSTRAK

Penelitian ini bertujuan untuk memprediksi penurunan motivasi belajar mahasiswa pada pembelajaran daring menggunakan algoritma Multilayer Perceptron (MLP) berdasarkan data aktivitas pengguna pada Learning Management System (LMS) Moodle. Permasalahan utama dalam pembelajaran daring adalah menurunnya motivasi belajar mahasiswa akibat rendahnya keterlibatan dalam aktivitas pembelajaran. Penelitian ini menggunakan pendekatan kuantitatif dengan metode supervised learning terhadap data aktivitas mahasiswa yang meliputi frekuensi login, durasi akses, dan aktivitas penggunaan Moodle. Data diproses melalui tahap preprocessing meliputi pembersihan data, normalisasi, seleksi fitur, serta pembagian data training dan testing. Model MLP kemudian dilatih untuk mempelajari pola hubungan aktivitas mahasiswa dengan kondisi motivasi belajar. Hasil penelitian menunjukkan bahwa algoritma MLP mampu menghasilkan performa prediksi yang baik dalam mengidentifikasi mahasiswa yang berpotensi mengalami penurunan motivasi belajar. Dengan demikian, model ini dapat membantu pendidik dalam melakukan deteksi dini terhadap penurunan motivasi belajar mahasiswa sehingga dapat mendukung pengambilan keputusan yang lebih efektif dalam pembelajaran daring.

Kata Kunci : Multilayer Perceptron (MLP); Moodle; machine learning; motivasi belajar; prediksi.

PREDICTING THE DECLINE OF LEARNING MOTIVATION IN MOODLE USERS USING MULTILAYER PERCEPTRON (MLP)

ABSTRACT

This study aims to predict the decline in students' learning motivation in online learning using the Multilayer Perceptron (MLP) algorithm based on user activity data in the Moodle Learning Management System (LMS). The main problem in online learning is the decline in students' learning motivation due to low engagement in learning activities. This study uses a quantitative approach with a supervised learning method on student activity data, including login frequency, access duration, and Moodle usage activities. The data were processed through preprocessing stages, including data cleaning, normalization, feature selection, and the division of training and testing data. The MLP model was then trained to learn the relationship patterns between student activities and learning motivation conditions. The results showed that the MLP algorithm was able to produce good predictive performance in identifying students who have the potential to experience a decline in learning motivation. Therefore, this model can help educators conduct early detection of decreased student learning motivation and support more effective decision-making in online learning.

Keywords: Multilayer Perceptron (MLP); Moodle; machine learning; learning motivation; prediction.

DAFTAR ISI

LEMBAR PENGESAHAN ..... **i**
PERNYATAAN ORISINALITAS ..... **ii**
PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN ..... **iii**
RIWAYAT HIDUP ..... **iv**
KATA PENGANTAR ..... **v**
ABSTRAK ..... **viii**
ABSTRACT ..... **ix**
DAFTAR TABEL ..... **xiii**
DAFTAR GAMBAR ..... **xiv**
BAB I PENDAHULUAN **1**
1.1 Latar Belakang Masalah 1
1.2 Rumusan Masalah 4
1.3 Batasan Masalah 4
1.4 Tujuan Penelitian 5
1.5 Manfaat Penelitian 5
BAB II LANDASAN TEORI **7**
2.1 Motivasi Belajar 7
2.2 Pembelajaran Daring 8
2.3 Learning Management System (LMS) 8
2.5 Machine Learning 10
2.6 Multilayer Perceptron 12
2.7 Flowchart 14
2.8 Penelitian Terdahulu 17
2.9 Analisis GAP 22
BAB III METODE PENELITIAN **25**
3.1 Jenis Penelitian 25
3.2 Flowchart Rancangan Penelitian 25
3.3 Flowchart Alur Penelitian 27
3.4 Sumber dan Jenis Data 28
3.5 Teknik Pengumpulan Data 30
3.6 Variabel Penelitian 31
3.7 Tahapan Pemodelan MLP dan Evaluasi Model 31
3.8 Perancangan Sistem 34
3.8.1 Use Case Diagram 35
3.9 Rancangan Antar Muka 36
3.9.1 Halaman Login 36
3.9.2 Halaman Input Data Aktivitas 37
3.9.3 Halaman Hasil Prediksi 38
BAB IV HASIL DAN PEMBAHASAN **41**
4.1 Gambaran Umum Data Penelitian 41
4.2 Hasil Preprocessing Data 42
4.2.1 Sumber dan Format Data Moodle 42
4.2.2 Standarisasi Struktur Data dan Penamaan Kolom 43
4.2.3 Pembersihan Data dan Pemeriksaan Missing Value 43

4.2.4 Validasi Nilai Tidak Wajar dan Konsistensi Data 44
4.2.5 Seleksi Fitur (Feature Selection) 45
4.2.6 Normalisasi Fitur Numerik dengan StandardScaler 46
4.2.7 Penanganan Ketidakseimbangan Kelas (Imbalanced Class) 47
4.2.8 Pembagian Data Latih dan Data Uji 48
4.3 Pemodelan Multilayer Perceptron (MLP) 48
4.3.1 Arsitektur Model MLP 49
4.3.2 Penentuan Hyperparameter Model 49
4.3.3 Pelatihan Model MLP 50
4.3.4 Kurva Loss Pelatihan (Training Loss Curve) 51
4.3.5 Hasil Prediksi pada Data Uji 51
4.4 Evaluasi Kinerja Model 52
4.4.1 Confusion Matrix 52
4.4.2 Metrik Akurasi 53
4.4.3 Metrik Presisi (Precision) 53
4.4.4 Metrik Recall (Sensitivity) 54
4.4.5 Metrik F1-Score 54
4.4.6 Perbandingan Performa dengan Baseline Model 55
4.5 Analisis Hasil Prediksi Penurunan Motivasi Belajar 55
4.5.1 Distribusi Prediksi Motivasi Mahasiswa 55
4.5.2 Segmentasi Risiko Berdasarkan Probabilitas Prediksi 55
4.5.3 Analisis Korelasi Variabel terhadap Penurunan Motivasi 56
4.5.4 Identifikasi Mahasiswa Berpotensi Risiko Tinggi 61
4.6 Pembahasan 63
4.6.1 Interpretasi Kinerja Model MLP 63
4.6.2 Pengaruh Aktivitas Login Terhadap Motivasi Belajar 63
4.6.3 Implikasi Praktis bagi Pengelolaan Pembelajaran Daring 65
4.6.4 Keterbatasan Penelitian 65
BAB V KESIMPULAN DAN SARAN 67
5.1 Kesimpulan 67
5.2 Saran 68
DAFTAR PUSTAKA 70

DAFTAR TABEL

Tabel 2.1 Simbol Flowchart 15
Table 2.2 Ringkasan Penelitian Terdahulu 16
Tabel 3.1 Jadwal Penelitian 40
Tabel 4.1 Gambaran Statistik Deskriptif Dataset Aktivitas Moodle 41
Tabel 4.2 Hasil Pemeriksaan Missing Value 43
Tabel 4.3 Distribusi Nilai Sebelum dan Sesudah Normalisasi 47
Tabel 4.4 Distribusi Data Latih dan Data Uji 48
Tabel 4.5 Konfigurasi Hyperparameter Model MLP 49
Tabel 4.6 Confusion Matrix Hasil Prediksi Model MLP 52
Tabel 4.7 Hasil Metrik Evaluasi Model MLP 55
Tabel 4.8 Segmentasi Risiko Berdasarkan Probabilitas Prediksi MLP 56
Tabel 4.9 Daftar 5 Mahasiswa Probabilitas Penurunan Motivasi Tertinggi 62

DAFTAR GAMBAR

Gambar 2.1 Ilustrasi Multilayer Perceptron 13
Gambar 3.1 Flowchart Rancangan Penelitian 26
Gambar 3.2 Flowchart Alur Penelitian..... 28
Gambar 3.3 Use Case Admin 36
Gambar 3.4 Halaman Login 37
Gambar 3.5 Halaman Input Data Aktivitas 38
Gambar 3.6 Halaman Hasil Prediksi 39
Gambar 4.1 Kurva Loss Pelatihan Model MLP..... 51
Gambar 4.2 Matriks Korelasi Pearson Variabel Independen..... 57
Gambar 4.3 Box Plot Jumlah Login terhadap Motivasi Belajar 64

BAB I

PEMDAHULUAN

1.1 Latar Belakang Masalah

Motivasi belajar merupakan faktor fundamental yang memengaruhi keberhasilan proses pembelajaran karena berperan sebagai dorongan internal maupun eksternal yang mengarahkan individu dalam mencapai tujuan belajar. Motivasi tidak hanya menentukan tingkat keaktifan mahasiswa dalam mengikuti pembelajaran, tetapi juga memengaruhi ketekunan, minat, serta hasil belajar yang dicapai. Dalam konteks pendidikan modern, motivasi belajar menjadi elemen krusial yang harus diperhatikan untuk meningkatkan kualitas pembelajaran secara menyeluruh (Nurhalizah & Ardianto, 2024).

Motivasi belajar memiliki keterkaitan yang erat dengan tingkat keterlibatan mahasiswa dalam proses pembelajaran. Mahasiswa yang memiliki motivasi tinggi cenderung lebih aktif dalam mengakses materi, menyelesaikan tugas, serta berpartisipasi dalam diskusi akademik, sedangkan mahasiswa dengan motivasi rendah cenderung menunjukkan perilaku pasif. Dalam pembelajaran daring, kondisi ini menjadi semakin penting karena mahasiswa dituntut untuk memiliki kemandirian yang lebih tinggi akibat keterbatasan interaksi langsung dengan dosen (Wulandari et al., 2024).

Penurunan motivasi belajar merupakan permasalahan yang sering terjadi dalam pembelajaran daring, yang dipengaruhi oleh faktor seperti kejenuhan, kurangnya interaksi sosial, serta rendahnya keterlibatan dalam aktivitas pembelajaran. Seiring dengan perkembangan teknologi, data aktivitas mahasiswa seperti frekuensi login dan durasi akses pada Learning Management System

(LMS)

dapat dimanfaatkan sebagai indikator untuk menganalisis tingkat motivasi belajar secara lebih objektif. Dengan pendekatan berbasis data ini, pendidik dapat mendeteksi penurunan motivasi belajar mahasiswa secara lebih dini dan akurat (Yuda & Kurniawati, 2024).

Dalam konteks pembelajaran daring, diperlukan suatu media yang mampu mendukung proses pembelajaran sekaligus memantau keterlibatan mahasiswa. Learning Management System (LMS) hadir sebagai platform digital yang dirancang untuk mengelola proses pembelajaran secara terstruktur, mulai dari penyampaian materi, pemberian tugas, hingga evaluasi hasil belajar. LMS memungkinkan proses pembelajaran dilakukan secara fleksibel serta mendukung pembelajaran mandiri yang menjadi karakteristik utama dalam pendidikan modern(Regita, 2023).

Salah satu LMS yang banyak digunakan adalah Moodle (Modular Object-Oriented Dynamic Learning Environment), yaitu platform open-source yang menyediakan berbagai fitur pembelajaran seperti materi digital, forum diskusi, kuis, serta pengumpulan tugas. Moodle tidak hanya berfungsi sebagai media pembelajaran, tetapi juga mampu meningkatkan interaksi antara dosen dan mahasiswa melalui berbagai aktivitas yang terintegrasi dalam sistem. Pemanfaatan Moodle terbukti dapat mendukung pembelajaran daring secara lebih efektif serta meningkatkan keterlibatan mahasiswa dalam proses pembelajaran (Ika et al., 2023).

Selain itu, Moodle memiliki keunggulan dalam merekam data aktivitas pengguna secara detail, seperti frekuensi login, durasi akses, serta tingkat

partisipasi mahasiswa. Data tersebut dapat dimanfaatkan sebagai indikator untuk mengukur keterlibatan mahasiswa yang berkaitan erat dengan motivasi belajar. Dengan adanya data aktivitas ini, pendidik dapat memperoleh gambaran yang lebih objektif mengenai kondisi pembelajaran, sehingga membuka peluang untuk dilakukan analisis lebih lanjut dalam mendeteksi penurunan motivasi belajar mahasiswa (Wulandari et al., 2024).

Pemanfaatan data aktivitas pada LMS seperti Moodle membuka peluang untuk dilakukan analisis berbasis teknologi guna memahami pola perilaku belajar mahasiswa. Dalam hal ini, pendekatan machine learning dapat digunakan untuk mengolah data aktivitas tersebut menjadi informasi yang lebih bermakna. Machine learning merupakan cabang dari kecerdasan buatan yang memungkinkan sistem untuk mempelajari pola dari data dan menghasilkan prediksi secara otomatis tanpa pemrograman eksplisit (Alnasyan et al., 2024).

Salah satu algoritma yang dapat digunakan dalam proses prediksi adalah Multilayer Perceptron (MLP), yang merupakan bagian dari jaringan saraf tiruan (neural network). MLP memiliki kemampuan dalam mempelajari hubungan nonlinier antar data melalui beberapa lapisan neuron, sehingga sangat cocok digunakan untuk menganalisis data yang kompleks seperti data aktivitas mahasiswa pada LMS. Proses pembelajaran dalam MLP dilakukan melalui mekanisme forward propagation dan backpropagation untuk menghasilkan model prediksi yang optimal (Gulo et al., 2024).

Dalam penelitian ini, algoritma MLP digunakan untuk memprediksi penurunan motivasi belajar mahasiswa berdasarkan data aktivitas login pada LMS Moodle. Aktivitas login dipilih sebagai indikator karena mencerminkan tingkat

keterlibatan mahasiswa dalam pembelajaran daring. Dengan memanfaatkan model prediksi berbasis MLP, diharapkan dapat dilakukan deteksi dini terhadap penurunan motivasi belajar mahasiswa, sehingga dapat membantu pendidik dalam mengambil langkah yang tepat untuk meningkatkan kualitas pembelajaran (Arti & Suherlan, 2025).

1.2 Rumusan Masalah

1. Bagaimana proses motivasi belajar mahasiswa dalam pembelajaran daring yang ditinjau dari aktivitas pada Learning Management System (LMS) Moodle?
2. Bagaimana penerapan algoritma Multilayer Perceptron (MLP) dalam memprediksi penurunan motivasi belajar mahasiswa berdasarkan data aktivitas pada LMS Moodle?
3. Bagaimana hasil pemanfaatan LMS Moodle dalam menyediakan data aktivitas mahasiswa yang berkaitan dengan motivasi belajar?

1.3 Batasan Masalah

1. Penelitian ini hanya menekankan pada penggunaan *Learning Management System* (LMS) Moodle sebagai objek utama, tanpa membahas secara detail platform pembelajaran online lainnya seperti *Google Classroom*, *Schoology*, *Microsoft Teams*, atau *Canva.*
2. Penelitian ini hanya mencakup prediksi penurunan motivasi belajar mahasiswa, tanpa menyentuh peningkatan motivasi, hasil pembelajaran, prestasi akademik, atau aspek psikologis lainnya selain motivasi belajar.
3. Data yang digunakan dalam penelitian ini terbatas pada aktivitas login pengguna *Moodle*, tanpa mencakup pengumpulan tugas, partisipasi di forum,

atau hasil kuis.

4. Metode penelitian ini hanya menggunakan algoritma *Multilayer Perceptron* (MLP), tanpa membandingkan hasil prediksinya dengan algoritma pembelajaran mesin atau deep learning lainnya.
5. Penelitian ini tidak membahas pengembangan keseluruhan sistem *Moodle* maupun keamanan sistem, melainkan hanya mengimplementasikan model prediksi dalam sistem berbasis web untuk menampilkan hasil prediksi penurunan motivasi belajar mahasiswa.
6. Hasil penelitian ini terbatas pada akurasi dan kinerja model MLP dalam memprediksi penurunan motivasi belajar, tanpa membahas penerapan kebijakan pendidikan atau intervensi pembelajaran secara langsung.

1.4 Tujuan Penelitian

1. Untuk menganalisis proses dan pola motivasi belajar mahasiswa dalam pembelajaran daring berdasarkan aktivitas pada Learning Management System (LMS) Moodle.
2. Untuk menganalisis pemanfaatan Learning Management System (LMS) Moodle dalam menyediakan data aktivitas mahasiswa yang berkaitan dengan motivasi belajar.
3. Untuk menerapkan algoritma Multilayer Perceptron (MLP) dalam memprediksi penurunan motivasi belajar mahasiswa berdasarkan data aktivitas pada LMS Moodle.

1.5 Manfaat Penelitian

1. Manfaat Teoritis

Penelitian ini diharapkan dapat menambah referensi dan wawasan keilmuan dalam bidang teknologi informasi dan pendidikan, khususnya terkait penerapan machine learning menggunakan algoritma *Multilayer Perceptron* (MLP) untuk memprediksi motivasi belajar siswa pada sistem pembelajaran daring berbasis *Moodle*.

2. Manfaat Praktis

   Hasil penelitian ini dapat menjadi bahan pertimbangan bagi pendidik dan pengelola LMS *Moodle* dalam memantau potensi penurunan motivasi belajar mahasiswa secara lebih dini, sehingga dapat dilakukan Langkah antisipatif untuk meningkatkan keterlibatan mahasiswa dalam pembelajaran daring.

BAB II

LANDASAN TEORI

2.1 Motivasi Belajar

Motivasi belajar adalah penggerak atau pendorong dalam diri manusia untuk menimbulkan keinginan untuk belajar. Motivasi belajar akan memberikan arah yang baik saat proses belajar sedang berlangsung. Motivasi belajar juga akan membantu siswa untuk mencapai tujuan utama dari belajar. Dengan kata lain, saat siswa berusaha dengan keras, terutama jika di sertai dengan motivasi belajar, maka akan menghasilkan hasil yang baik dan juga bisa bermanfaat bagi orang lain dan diri sendiri (Bela et al., 2025).

Motivasi belajar tidak hanya berperan sebagai pendorong tindakan belajar, tetapi juga berpengaruh dalam menentukan hasil belajar yang dicapai oleh siswa. Beberapa penelitian menunjukkan bahwa semakin tinggi motivasi belajar yang dimiliki siswa, semakin besar pula kemungkinan siswa untuk mencapai prestasi akademik yang baik. Sebagai contoh, penelitian yang dianalisis menunjukkan bahwa motivasi belajar memiliki hubungan positif dan signifikan dengan hasil belajar siswa, di mana siswa yang termotivasi cenderung aktif dalam kegiatan pembelajaran dan lebih gigih dalam menyelesaikan tugas akademik sehingga berdampak pada prestasi belajar yang lebih baik dibandingkan mereka yang kurang termotivasi. Hasil penelitian ini menguatkan bahwa motivasi belajar merupakan salah satu faktor penting yang dapat meningkatkan efektivitas pembelajaran di sekolah. Dalam konteks penelitian ini, pembahasan motivasi belajar difokuskan pada mahasiswa sebagai subjek pembelajaran di perguruan tinggi, khususnya mahasiswa yang menggunakan Learning Management System

(LMS) Moodle (Muhammad Imam Syafi'i, Ramdanil Mubarok, 2019).

2.2 Pembelajaran Daring

Pembelajaran daring adalah penggunaan internet untuk melakukan akses materi belajar, untuk melakukan interaksi dengan materi; instruktur (guru atau dosen) dan pembelajar yang lain, untuk mendapatkan dukungan selama proses pembelajaran yang bertujuan agar memperoleh pengetahuan, menciptakan pemahaman dan untuk berkembang dari pengalaman belajar (Diva et al., 2021).

Pembelajaran daring telah berkembang menjadi salah satu pendekatan pembelajaran utama di era digital, khususnya setelah pandemi COVID-19 yang memaksa lembaga pendidikan di Indonesia untuk mengadopsi pembelajaran jarak jauh secara luas. Pembelajaran daring digunakan sebagai alternatif untuk menjaga kelangsungan proses belajar melalui teknologi digital yang berfungsi sebagai sarana penyampaian materi, komunikasi, dan evaluasi. Namun, keberhasilan pembelajaran daring sangat ditentukan oleh kesiapan infrastruktur teknologi, kemampuan pengajar dalam menangani pembelajaran digital, serta tingkat otonomi siswa dalam mengikuti proses pembelajaran (Budiman, 2021).

2.3 Learning Management System (LMS)

Sejarah pengembangan LMS dimulai pada awal tahun 1990-an, dengan munculnya berbagai perangkat lunak edukasi yang ditujukan untuk institusi pendidikan dan organisasi. Sejak saat itu, LMS telah mengalami evolusi yang signifikan baik dari segi teknologi yang digunakan maupun model interaksi dan kolaborasi yang dihadirkan dalam platform tersebut. Secara umum, LMS bertujuan ntuk memudahkan instruktur dalam menyampaikan materi pembelajaran, mengelola interaksi online antara peserta didik dan instruktur, serta

menyederhanakan tugas administrasi seperti penugasan, pengumpulan jawaban, dan penilaian. Beberapa contoh LMS populer yang digunakan oleh institusi pendidikan dan organisasi di seluruh dunia meliputi *Moodle* dan *Canva* (Regita, 2023).

Learning Management System (LMS) adalah *platform digital* yang secara khusus dirancang untuk mendukung proses pembelajaran, menyediakan konten edukasi, serta melacak dan menilai kinerja peserta didik di sebuah institusi atau organisasi. *Learning Management System* (LMS) menggabungkan teknologi dan metode pengajaran untuk menciptakan lingkungan belajar yang lebih interaktif, fleksibel, dan efisien.

Dalam perkembangannya, pemanfaatan *Learning Management System* (LMS) tidak berfungsi sebagai penyampaian materi ajar, tetapi juga sebagai alat untuk memantau aktivitas belajar siswa secara berkelanjutan. LMS mampu merekam data aktivitas pengguna, seperti frekuensi akses, durasi penggunaan, dan tingkat keterlibatan dalam pembelajaran daring, yang kemudian dapat dimanfaatkan untuk mengukur efektivitas proses pendidikan. Implementasi LMS yang optimal juga membantu para pengajar dalam mengambil keputusan berbasis data terkait progres dan partisipasi siswa, khususnya dalam skenario pembelajaran jarak jauh serta pembelajaran campuran (Wulandari et al., 2024).

2.4 *Moodle*

Moodle merupakan *Learning Management System* (LMS) yang bersifat *open-source* dan sering dimanfaatkan oleh institusi pendidikan sebagai alat bantu untuk pembelajaran jarak jauh atau campuran (gabungan antara tatap muka dan online). *Moodle* menawarkan berbagai fungsi edukasi, termasuk pengaturan

konten ajar, ruang diskusi, tugas, tes, serta sistem evaluasi yang saling terkoneksi, sehingga proses belajar dapat meningkatkan tingkat interaksi dan partisipasi siswa. Berkat desain yang terstruktur dan dapat disesuaikan, Moodle membantu guru dan dosen dalam mengorganisir materi dengan tertib serta memungkinkan peserta didik untuk mengikuti pembelajaran (Putra, 2022).

Moodle juga telah banyak diterapkan di berbagai lingkungan pendidikan di Indonesia untuk memperbaiki proses belajar, khususnya pada masa digital dan setelah pandemi. Riset pengembangan bahan ajar berbasis Moodle mengungkapkan bahwa inovasi ini mampu meningkatkan pembelajaran melalui pemanfaatan teknologi digital yang efisien, seperti dalam penyampaian konten yang menarik dan penilaian belajar yang dapat diukur (Yuda & Kurniawati, 2024).

2.5 Machine Learning

Machine Learning merupakan salah satu komponen dasar dalam bidang kecerdasan buatan yang digunakan untuk menangani berbagai permasalahan kompleks. Konsep ini merepresentasikan penerapan kecerdasan buatan yang berfokus pada pengembangan sistem berbasis data yang mampu melakukan proses pembelajaran secara mandiri tanpa memerlukan pemrograman berulang. Berdasarkan teknik pembelajarannya, machine learning terbagi menjadi *supervised learning* yang memanfaatkan data berlabel sebagai data pelatihan, serta *unsupervised learning* yang bekerja dengan mengidentifikasi pola dan struktur dari data tanpa label. Secara umum, machine learning dapat didefinisikan sebagai ilmu yang mempelajari pengembangan algoritma dan model statistik yang memungkinkan sistem komputer menjalankan tugas tertentu tanpa instruksi

eksplisit, melainkan melalui pemanfaatan pola dan inferensi yang diperoleh dari data.

Dalam penerapannya, algoritma *machine learning* digunakan untuk melatih sistem agar mampu memproses data secara lebih efisien dan optimal. Melalui proses identifikasi pola dalam kumpulan data, machine learning dapat melakukan prediksi serta mengenali karakteristik atau atribut dari objek yang sebelumnya belum diketahui.

Keunggulan pemanfaatan machine learning dalam evaluasi sistematis terletak pada kemampuannya dalam mengurangi kebutuhan terhadap pekerjaan manual yang bersifat berulang. Selain itu, machine learning mengandalkan algoritma yang mampu mempelajari pola dan hubungan kompleks dalam data tanpa bergantung pada pendekatan berbasis aturan, sehingga mendukung proses pengambilan keputusan dengan tingkat akurasi yang lebih tinggi (Nurhalizah & Ardianto, 2024).

2.6 Analisis Korelasi

Analisis korelasi merupakan salah satu metode statistik yang digunakan untuk mengetahui tingkat hubungan antara dua variabel atau lebih. Melalui analisis ini, peneliti dapat memahami apakah perubahan pada suatu variabel berkaitan dengan perubahan pada variabel lainnya, baik secara searah (positif), berlawanan arah (negatif), maupun tidak memiliki hubungan sama sekali. Hubungan tersebut dinyatakan dalam bentuk koefisien korelasi yang nilainya berkisar antara -1 hingga +1, di mana semakin mendekati angka tersebut menunjukkan hubungan yang semakin kuat.

Analisis korelasi juga memiliki beberapa jenis yang umum digunakan,

seperti korelasi Pearson, Spearman, dan Kendall, yang masing-masing digunakan sesuai dengan karakteristik data yang dianalisis. Pemilihan jenis korelasi yang tepat sangat penting agar hasil analisis dapat memberikan gambaran yang akurat. Dalam penelitian, teknik ini sering dimanfaatkan sebagai langkah awal untuk melihat adanya hubungan antar variabel sebelum dilakukan analisis lanjutan, sehingga peneliti dapat memperoleh pemahaman yang lebih mendalam terhadap data yang diteliti (Sari et al., 2024).

Adapun untuk mengukur tingkat hubungan antara variabel dalam penelitian ini, digunakan rumus korelasi pearson yang ditampilkan pada (Sumber : (Folorunsho et al., 2025) sebagai berikut:

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}}$$

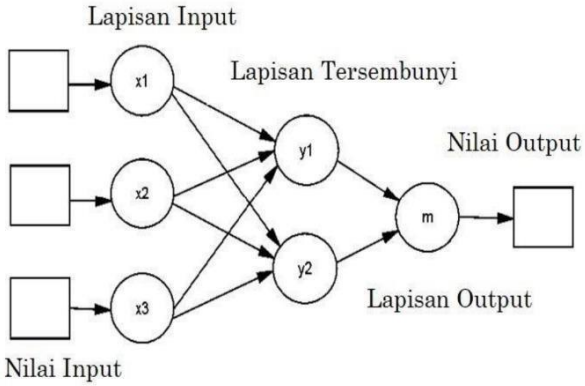
Keterangan:

- x_i : Nilai data ke-i pada variabel X (misal: frekuensi_login)
- y_i : Nilai data ke-i pada variabel Y (misal: prob_turun)
- $\bar{x}$: Rata-rata populasi/sampel variabel X
- $\bar{y}$: Rata-rata populasi/sampel variabel Y

2.7 Multilayer Perceptron

Multilayer Perceptron (MLP) merupakan salah satu algoritma pembelajaran mesin yang tergolong dalam kategori jaringan saraf buatan (*neural network*). MLP terdiri dari beberapa lapisan neuron, yakni lapisan masukan, satu atau lebih lapisan tersembunyi, dan lapisan keluaran, yang saling terhubung melalui bobot (*weights*) dan bias. Algoritma ini dikembangkan untuk mempelajari hubungan nonlinier antar data dengan menyesuaikan bobot koneksi antar neuron

selama fase pelatihan, sehingga dapat diterapkan untuk tugas klasifikasi maupun prediksi berdasarkan data (Gulo et al., 2024). Berikut Gambar 2.1 Ilustrasi Multilayer Perceptron:



Gambar 2.1 Ilustrasi Multilayer Perceptron

Tahapan penelitian yang melibatkan algoritma *Multilayer Perceptron* dimulai dengan pengumpulan data dari sumber yang sesuai dengan objektif penelitian. Data yang dikumpulkan selanjutnya menjalani tahap *pra-pemrosesan*, yang mencakup pembersihan data, penanganan nilai yang hilang (*missing value*), normalisasi, serta seleksi fitur untuk memastikan data siap digunakan oleh model. Berikutnya, dataset dibagi menjadi bagian data pelatihan dan data pengujian. Pada fase selanjutnya, dilakukan perancangan arsitektur MLP dengan menentukan jumlah neuron pada lapisan masukan, jumlah lapisan tersembunyi, jumlah neuron di setiap lapisan tersembunyi, serta fungsi aktivasi yang diterapkan. Model kemudian dilatih menggunakan data pelatihan melalui mekanisme propagasi maju dan propagasi balik untuk memperbarui bobot serta bias. Setelah pelatihan selesai, model dievaluasi dengan menggunakan data pengujian guna mengukur kinerja prediksi yang dihasilkan (Nugroho, 2023).

Proses pembelajaran dalam *Multilayer Perceptron* melibatkan beberapa

tahap utama, yakni propagasi maju (*forward propagation*), penghitungan kesalahan (error), propagasi balik (*backpropagation*), serta pembaruan bobot. Pada fase propagasi maju, data masukan dikirimkan dari lapisan input ke lapisan tersembunyi hingga lapisan output. Keluaran yang dihasilkan selanjutnya dibandingkan dengan nilai target untuk menentukan kesalahan. Kemudian, kesalahan tersebut dipropagasikan kembali ke lapisan sebelumnya melalui *backpropagation* guna menghitung gradien kesalahan terhadap bobot. Bobot dan bias kemudian disesuaikan menggunakan algoritma gradient descent. Siklus ini diulangi hingga kesalahan mencapai ambang minimum atau mencapai konvergensi (Nugroho, 2023).

Rumus pendekatan perhitungan output pada setiap neuron dalam *Multilayer Perceptron* yang ditampilkan pada (Sumber : (Gulo et al., 2024) sebagai berikut :

$$y = f\left(\sum_{i=1}^{n} w_i x_i + b\right)$$

Dengan keterangan:

- X_i = nilai input
- W_i = bobot koneksi
- b = bias
- f (.) = fungsi
- y = output neuron

2.8 Flowchart

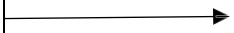
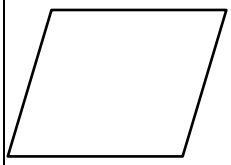
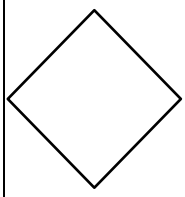
Flowchart merupakan diagram visual yang mengilustrasikan langkah-

langkah secara berurutan dan secara eksklusif digunakan untuk merepresentasikan algoritma. Diagram ini menunjukkan keterkaitan antara proses dan instruksi komputasional. Representasi tersebut diwujudkan melalui penggunaan simbol-simbol. Akibatnya, setiap simbol mewakili proses yang berbeda. Garis penghubung mengindikasikan proses yang berjalan secara simultan. Penerapan diagram alur dalam evaluasi suatu masalah memfasilitasi identifikasi komponen yang hilang. Diagram alur dapat dimanfaatkan oleh analis dan pengembang untuk menganalisis berbagai tindakan serta membedah masalah menjadi elemen-elemen yang lebih kecil (Pratama & Eviyanti, 2024).

Flowchart memiliki fungsi utama dalam mengklarifikasi urutan operasional suatu sistem, sehingga memfasilitasi pengembang dan analis dalam merancang langkah-langkah kerja secara logis sebelum fase implementasi. Representasi visual tahapan kerja melalui simbol-simbol baku memungkinkan pemahaman mendalam terhadap setiap proses yang akan dikembangkan oleh berbagai pemangku kepentingan, baik dari kalangan teknis maupun non-teknis. Selain itu, flowchart dapat berfungsi sebagai dokumentasi awal dalam pengembangan sistem, yang berperan sebagai referensi saat melakukan penulisan kode atau pengujian sistem. Oleh karena itu, penerapan flowchart berkontribusi terhadap efisiensi dan ketepatan dalam perancangan sistem informasi, dengan cara mengurangi kesalahan logika serta mempertajam pemahaman tentang interaksi antarproses dalam sistem (Manajemen et al., 2024). Berikut simbol flowchart yang ditampilkan Tabel 2.1 (Sumber : (Akuntansi et al., 2024).

Tabel 2.1 Simbol Flowchart

Simbol	Nama	Fungsi

Simbol	Nama	Fungsi
	Terminal	Simbol yang menyatakan awal (*start*) atau akhir (*finish*) suatu sistem
	Flowline	Simbol ini digunakan untuk menunjukkan arah aliran atau urutan dari suatu proses
	Process	Simbol ini digunakan untuk menunjukkan suatu aktivitas atau proses yang akan divisualisasikan dalam alur sistem
	Input/Output	Simbol yang menyatakan proses Input atau Output
	Decision	Symbol ini berfungsi sebagai penentuan pengambilan Keputusan pada Langkah selanjutnya dalam sebuah proses.

2.9 Penelitian Terdahulu

Table 2.2 Ringkasan Penelitian Terdahulu

NO	Judul dan Penelitian	Pembahasan	Metode	Kelebihan dan Kekurangan
1.	Prediksi Performa Mahasiswa Berdasarkan Aktivitas LMS Menggunakan Neural Network (Ardianti et al., 2024)	Penelitian ini menggunakan data aktivitas LMS seperti login, akses materi, dan interaksi untuk memprediksi performa mahasiswa menggunakan neural network. Data aktivitas digunakan sebagai indikator perilaku belajar mahasiswa dalam pembelajaran daring.	Neural Network (MLP-based)	Kelebihan: Sangat dekat dengan penelitian karena menggunakan data LMS dan metode neural network. Kekurangan: Tidak secara spesifik membahas motivasi belajar sebagai variabel utama.
2.	Learning Analytics untuk Prediksi Performa Mahasiswa Berbasis Data LMS (Azis, 2025)	Penelitian ini membahas penggunaan data aktivitas LMS seperti login, akses materi, dan interaksi untuk memprediksi performa mahasiswa. Data aktivitas	Machine Learning	Kelebihan: Menggunakan data LMS langsung dan relevan dengan perilaku belajar. Kekurangan: Tidak membahas motivasi belajar

		digunakan sebagai indikator perilaku belajar mahasiswa.		dan tidak menggunakan MLP.
3.	Penerapan Jaringan Saraf Tiruan Multilayer Perceptron untuk Prediksi Kelulusan Kinerja Akademik Mahasiswa (Mardinah & Thoriq, 2022)	Penelitian ini menggunakan algoritma Jaringan Saraf Tiruan Multilayer Perceptron (MLP) untuk memprediksi kinerja akademik mahasiswa berdasarkan data akademik seperti indeks prestasi dan jumlah SKS. Hasil penelitian menunjukkan bahwa model MLP mampu menghasilkan prediksi dengan tingkat akurasi yang tinggi karena dapat menangkap pola	Multilayer Perceptron (MLP)	Kelebihan: Menggunakan algoritma Multilayer Perceptron yang mampu memodelkan hubungan nonlinier sehingga menghasilkan prediksi kinerja akademik mahasiswa dengan akurasi yang baik. Kekurangan: Penelitian ini hanya berfokus pada kinerja akademik dan

		hubungan nonlinier dalam data pendidikan.		belum membahas motivasi belajar mahasiswa secara langsung.
4.	Applying Learning Analytics in Online Environments to Understand Student Engagement (Caspari-Sadeghi, 2022)	Penelitian ini membahas pemanfaatan learning analytics dalam lingkungan pembelajaran daring untuk menganalisis keterlibatan mahasiswa berdasarkan data aktivitas pada Learning Management System (LMS). Data aktivitas seperti akses materi, interaksi, dan jejak	Learning Analytics & Machine Learning	Kelebihan: Menggunakan data LMS secara langsung. Kekurangan: Tidak secara spesifik menggunakan algoritma MLP.

		digital mahasiswa digunakan untuk mengidentifikasi pola engagement selama proses pembelajaran. Hasil penelitian menunjukkan bahwa data aktivitas LMS dapat digunakan untuk memantau keterlibatan mahasiswa secara real-time dan membantu pengambilan keputusan dalam pembelajaran.		

5.	Prediksi Tingkat Keterlibatan dan Motivasi Belajar Mahasiswa dalam Pembelajaran Daring Menggunakan Machine Learning (Johar et al., 2023)	Penelitian ini membahas penggunaan metode machine learning untuk menganalisis dan memprediksi tingkat keterlibatan serta motivasi belajar mahasiswa dalam pembelajaran daring. Data yang digunakan berasal dari aktivitas mahasiswa pada sistem pembelajaran digital, seperti frekuensi akses, interaksi, dan partisipasi dalam kegiatan belajar. Hasil penelitian menunjukkan bahwa pola aktivitas mahasiswa dapat digunakan untuk	Machine Learning (Neural Network)	Kelebihan: Menganalisis keterlibatan yang secara langsung berkaitan dengan motivasi belajar menggunakan pendekatan machine learning berbasis data aktivitas mahasiswa. Kekurangan: Tidak menggunakan algoritma Multilayer Perceptron secara spesifik sebagai metode utama.

		mengidentifikasi tingkat motivasi belajar serta perubahan perilaku belajar selama proses pembelajaran berlangsung.		

2.10 Analisis GAP

Berdasarkan hasil kajian terhadap beberapa penelitian terdahulu yang telah dibahas pada subbab sebelumnya, dapat diketahui bahwa pemanfaatan Learning Management System (LMS) dan pendekatan machine learning dalam dunia pendidikan telah banyak dilakukan dengan berbagai fokus dan metode. Penelitian yang dilakukan oleh Ardianti et al. (2024) menunjukkan bahwa data aktivitas pada LMS seperti login, akses materi, dan interaksi dapat digunakan untuk memprediksi performa mahasiswa menggunakan metode neural network. Meskipun penelitian tersebut relevan dalam memanfaatkan data aktivitas LMS, fokus yang dilakukan masih terbatas pada prediksi performa akademik dan belum secara langsung membahas motivasi belajar mahasiswa (Ardianti et al., 2024).

Penelitian yang dilakukan oleh Azis (2025) juga memanfaatkan data aktivitas LMS untuk memprediksi performa mahasiswa dengan pendekatan machine learning. Hasil penelitian menunjukkan bahwa data aktivitas dapat digunakan sebagai indikator perilaku belajar mahasiswa. Namun demikian, penelitian ini belum menggunakan algoritma Multilayer Perceptron (MLP) secara spesifik serta tidak membahas motivasi belajar sebagai variabel utama dalam

analisis (Azis, 2025).

Selanjutnya, penelitian oleh Mardinah dan Thoriq (2022) menggunakan algoritma Multilayer Perceptron (MLP) untuk memprediksi kinerja akademik mahasiswa berdasarkan data akademik. Penelitian ini menunjukkan bahwa MLP memiliki kemampuan yang baik dalam memodelkan hubungan nonlinier sehingga menghasilkan prediksi yang akurat. Meskipun demikian, penelitian ini tidak menggunakan data aktivitas LMS serta belum membahas aspek motivasi belajar mahasiswa (Mardinah & Thoriq, 2022).

Penelitian oleh Caspari-Sadeghi (2022) membahas pemanfaatan learning analytics dalam menganalisis keterlibatan mahasiswa berdasarkan data aktivitas LMS. Hasil penelitian menunjukkan bahwa aktivitas mahasiswa dapat digunakan untuk memantau keterlibatan secara real-time. Namun, penelitian ini tidak menggunakan algoritma Multilayer Perceptron (MLP) sebagai metode utama serta belum secara spesifik memprediksi motivasi belajar mahasiswa (Caspari-Sadeghi, 2022).

Selain itu, penelitian oleh Johar et al. (2023) menunjukkan bahwa metode machine learning dapat digunakan untuk menganalisis keterlibatan dan motivasi belajar mahasiswa berdasarkan data aktivitas pembelajaran daring. Penelitian ini telah membahas keterkaitan antara keterlibatan dan motivasi belajar, namun belum secara spesifik menggunakan algoritma Multilayer Perceptron (MLP) serta belum memfokuskan pada analisis aktivitas login sebagai indikator utama dalam prediksi (Johar et al., 2023).

Berdasarkan uraian tersebut, dapat disimpulkan bahwa masih terdapat beberapa celah penelitian yang belum banyak dikaji secara mendalam. Pertama,

sebagian besar penelitian sebelumnya lebih berfokus pada prediksi performa akademik dibandingkan dengan motivasi belajar mahasiswa. Kedua, penelitian yang membahas motivasi belajar umumnya belum menggunakan algoritma Multilayer Perceptron (MLP) secara spesifik. Ketiga, penelitian yang menggunakan MLP belum memanfaatkan data aktivitas pada Learning Management System (LMS) sebagai sumber utama data. Keempat, belum terdapat penelitian yang secara khusus menggunakan aktivitas login pada LMS Moodle sebagai indikator utama dalam memprediksi penurunan motivasi belajar mahasiswa.

Oleh karena itu, penelitian ini dilakukan untuk mengisi celah tersebut dengan mengombinasikan penggunaan data aktivitas login pada Learning Management System (LMS) Moodle dengan algoritma Multilayer Perceptron (MLP) untuk memprediksi penurunan motivasi belajar mahasiswa. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan pemanfaatan machine learning pada sistem pembelajaran daring berbasis LMS, khususnya dalam mendukung pemantauan motivasi belajar mahasiswa secara lebih efektif, objektif, dan berbasis data.

BAB III

METODE PENELITIAN

3.1 Jenis Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk membangun dan menguji kinerja algoritma Multilayer Perceptron (MLP) dalam memprediksi penurunan motivasi belajar mahasiswa berdasarkan data aktivitas pengguna pada *Learning Management System* (LMS) Moodle. Pendekatan ini dipilih karena data yang digunakan bersifat numerik dan dapat dianalisis secara matematis sehingga menghasilkan model prediksi yang objektif dan terukur.

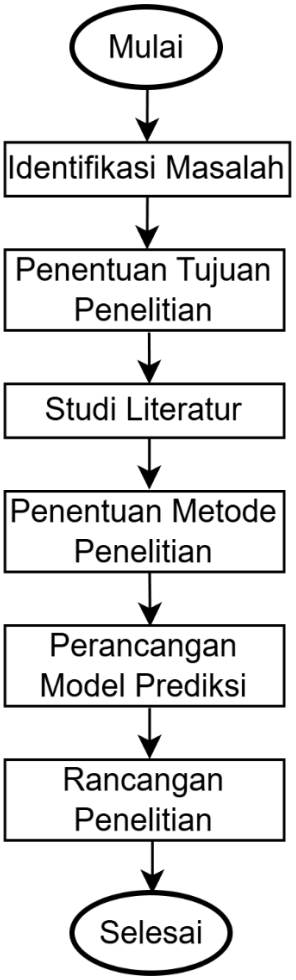
Berdasarkan tujuannya, penelitian ini termasuk dalam penelitian terapan (*applied research*), karena hasil penelitian diharapkan dapat dimanfaatkan secara langsung sebagai alat bantu pemantauan motivasi belajar mahasiswa pada pembelajaran daring. Tahapan penelitian meliputi studi literatur, pengumpulan data aktivitas login pengguna Moodle, pra-pemrosesan data, pemodelan menggunakan algoritma MLP, serta pengujian dan evaluasi model untuk menilai kinerja prediksi yang dihasilkan.

3.2 Flowchart Rancangan Penelitian

Rancangan penelitian digunakan sebagai kerangka dasar dalam pelaksanaan penelitian agar seluruh tahapan penelitian dapat dilakukan secara sistematis dan terarah sesuai dengan tujuan yang telah ditetapkan. Rancangan penelitian ini menggambarkan desain umum penelitian yang mencakup tahapan utama mulai dari identifikasi masalah, penentuan tujuan penelitian, studi literatur,

penentuan metode penelitian, hingga perancangan model prediksi penurunan motivasi belajar mahasiswa menggunakan algoritma Multilayer Perceptron.

Untuk memberikan gambaran yang lebih jelas mengenai desain penelitian yang digunakan, rancangan penelitian divisualisasikan dalam bentuk flowchart. Flowchart rancangan penelitian tersebut ditunjukkan pada Gambar 3.1, yang menggambarkan tahapan penelitian secara umum sebelum memasuki tahap pelaksanaan teknis dan operasional.

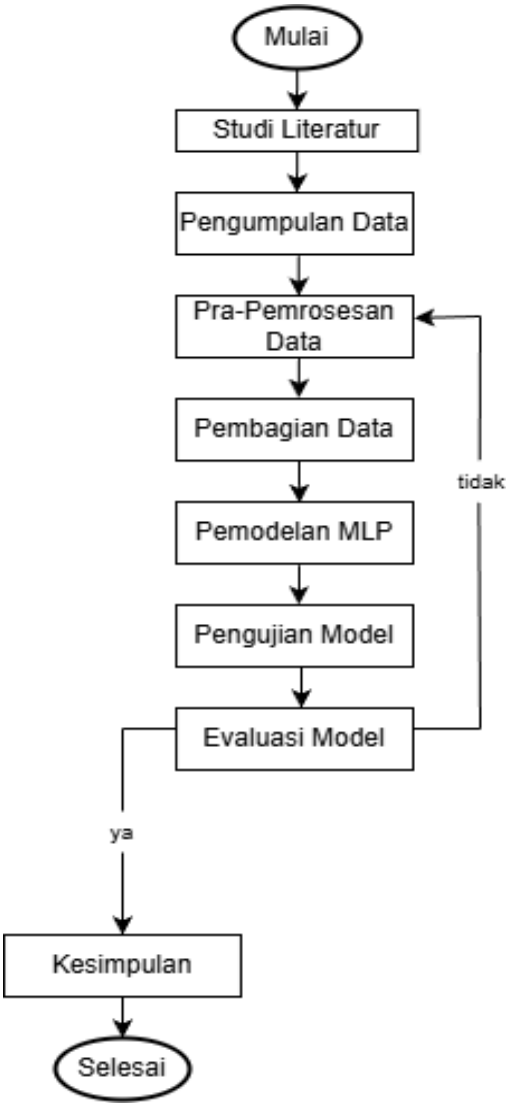


Gambar 3.1 Flowchart Rancangan Penelitian

3.3 Flowchart Alur Penelitian

Flowchart alur penelitian digunakan untuk memberikan gambaran umum mengenai tahapan penelitian yang dilakukan secara sistematis dan terstruktur. Penyajian alur penelitian dalam bentuk flowchart bertujuan agar proses penelitian dapat dipahami dengan lebih jelas, mulai dari tahap awal hingga tahap akhir sesuai dengan tujuan penelitian.

Dalam penelitian ini, flowchart alur penelitian menggambarkan rangkaian proses pengolahan data aktivitas pengguna Moodle yang digunakan sebagai dasar dalam membangun model prediksi penurunan motivasi belajar mahasiswa menggunakan algoritma Multilayer Perceptron (MLP). Flowchart tersebut mencakup tahapan utama penelitian seperti pengumpulan data, pra-pemrosesan, proses pemodelan, hingga evaluasi hasil prediksi yang diperoleh. Adapun flowchart alur penelitian yang digunakan dalam penelitian ini ditunjukkan pada Gambar 3.2.



Gambar 3.2 Flowchart Alur Penelitian

3.4 Sumber dan Jenis Data

Data yang digunakan dalam penelitian ini bersumber dari Learning Management System (LMS) Moodle yang digunakan di Universitas Muhammadiyah Sumatera Utara (UMSU). Data yang diambil merupakan data aktivitas pengguna yang terekam secara otomatis dalam sistem Moodle, khususnya aktivitas login mahasiswa selama proses pembelajaran daring berlangsung. Data aktivitas login tersebut digunakan sebagai dasar dalam membangun model prediksi

penurunan motivasi belajar mahasiswa.

Objek penelitian difokuskan pada mahasiswa aktif Universitas Muhammadiyah Sumatera Utara (UMSU) semester 4. Pemilihan mahasiswa semester 4 dilakukan karena pada tahap ini mahasiswa umumnya telah beradaptasi dengan sistem pembelajaran di perguruan tinggi, sehingga pola aktivitas belajarnya lebih stabil dan dapat dianalisis untuk mendeteksi indikasi perubahan motivasi belajar secara lebih akurat.

Data yang digunakan dalam penelitian ini berupa data aktivitas login mahasiswa yang diperoleh dari sistem Moodle, yang meliputi jumlah login, frekuensi login dalam periode tertentu, serta pola perubahan aktivitas login selama proses pembelajaran berlangsung. Data tersebut kemudian disusun dalam bentuk dataset yang terstruktur untuk digunakan dalam proses pelatihan dan pengujian model Multilayer Perceptron (MLP).

Berdasarkan sumber perolehannya, data dalam penelitian ini termasuk dalam jenis data sekunder karena diperoleh dari sistem pembelajaran daring yang sudah berjalan dan tersimpan secara otomatis tanpa dilakukan pengumpulan data secara langsung melalui kuesioner atau wawancara. Selain itu, data yang digunakan juga termasuk ke dalam data kuantitatif karena berupa angka yang dapat diolah secara matematis dan dianalisis menggunakan metode machine learning.

Pemanfaatan data aktivitas login sebagai dataset penelitian didasarkan pada asumsi bahwa aktivitas login mencerminkan tingkat keterlibatan mahasiswa dalam pembelajaran daring. Penurunan frekuensi login dapat menjadi indikator awal terjadinya penurunan motivasi belajar mahasiswa, sehingga data tersebut relevan untuk digunakan dalam proses prediksi menggunakan algoritma Multilayer

Perceptron (MLP). Dataset yang digunakan disusun dalam bentuk tabel dengan setiap baris merepresentasikan satu mahasiswa dan setiap kolom merepresentasikan variabel aktivitas login seperti jumlah login, frekuensi login, dan pola perubahan aktivitas dalam periode tertentu.

3.5 Teknik Pengumpulan Data

Data penelitian diperoleh dari sistem Learning Management System (LMS) Moodle yang digunakan di Universitas Muhammadiyah Sumatera Utara (UMSU). Data yang dimanfaatkan berupa data aktivitas login mahasiswa semester 4 yang tercatat secara otomatis di dalam sistem selama pelaksanaan pembelajaran daring. Pengambilan data dilakukan melalui fitur pelaporan (*log report*) pada Moodle dengan cara mengekstraksi data berdasarkan rentang waktu tertentu serta jenis aktivitas login yang dibutuhkan. Data yang telah diperoleh kemudian disimpan dalam bentuk file digital, seperti CSV atau Excel, untuk memudahkan proses pengolahan pada tahap selanjutnya.

Data yang telah diekstraksi kemudian diseleksi sesuai dengan kriteria penelitian, yaitu mahasiswa aktif semester 4. Proses ini mencakup pemeriksaan kelengkapan data, penghapusan data yang bersifat duplikat, serta penyesuaian format data agar lebih konsisten. Selanjutnya, data disusun kembali dalam bentuk dataset yang terstruktur sehingga dapat digunakan dalam tahap penentuan variabel penelitian dan proses pemodelan menggunakan algoritma Multilayer Perceptron (MLP).

3.6 Variabel Penelitian

Variabel penelitian merupakan suatu unsur yang ditetapkan untuk diamati dan dianalisis dalam penelitian guna memperoleh informasi yang sesuai dengan tujuan penelitian. Dalam penelitian ini digunakan dua variabel, yaitu variabel independent dan variabel dependen.

1. Variabel independen

   Variabel ini berupa aktivitas login mahasiswa pada Learning Management System (LMS) Moodle yang digunakan sebagai indikator tingkat keterlibatan mahasiswa dalam pembelajaran daring. Aktivitas tersebut direpresentasikan dalam bentuk data kuantitatif, seperti jumlah dan frekuensi login dalam periode tertentu serta pola perubahannya selama perkuliahan berlangsung, sehingga dapat dianalisis sebagai dasar dalam memprediksi penurunan motivasi belajar mahasiswa.

2. Variabel dependen

   Variabel ini berupa penurunan motivasi belajar mahasiswa yang berperan sebagai output prediksi dalam model Multilayer Perceptron (MLP). Variabel ini merepresentasikan hasil klasifikasi yang menunjukkan kondisi mahasiswa, yaitu apakah mengalami indikasi penurunan motivasi belajar atau tidak, berdasarkan pola aktivitas login yang dianalisis oleh model sehingga dapat digunakan sebagai dasar dalam proses prediksi.

3.7 Tahapan Pemodelan MLP dan Evaluasi Model

Tahapan pemodelan dalam penelitian ini dilakukan untuk membangun model prediksi penurunan motivasi belajar mahasiswa menggunakan algoritma Multilayer Perceptron (MLP). Proses ini dilaksanakan secara sistematis mulai dari

pengolahan data hingga evaluasi hasil prediksi, sehingga model yang dihasilkan dapat mendukung tujuan penelitian. Pengolahan data aktivitas login mahasiswa dilakukan secara optimal agar model mampu memberikan hasil prediksi yang akurat.

Pra-pemrosesan data (preprocessing) dilakukan terhadap data mentah hasil ekstraksi dari Moodle sebelum digunakan dalam pelatihan model. Kegiatan ini meliputi pemeriksaan kelengkapan data, penghapusan data duplikat, penyesuaian format, serta normalisasi apabila diperlukan. Dataset kemudian disusun dalam struktur yang sesuai dengan variabel penelitian sehingga dapat mendukung proses pembelajaran model secara lebih efektif.

Dataset yang telah diproses selanjutnya dibagi menjadi data pelatihan (training data) dan data pengujian (testing data). Data pelatihan digunakan untuk melatih model MLP dalam mengenali pola aktivitas login mahasiswa, sedangkan data pengujian digunakan untuk mengukur kemampuan model dalam melakukan prediksi terhadap data yang belum pernah dipelajari sebelumnya. Perancangan arsitektur MLP dilakukan dengan menentukan jumlah neuron pada lapisan input, hidden layer, dan lapisan output, serta fungsi aktivasi yang digunakan. Proses pelatihan berlangsung melalui mekanisme forward propagation dan backpropagation hingga tingkat kesalahan mencapai nilai minimum.

Evaluasi model dilakukan dengan membandingkan hasil prediksi terhadap data aktual pada data pengujian. Pengukuran kinerja model dilakukan menggunakan metrik seperti akurasi, precision, recall, dan F1-score untuk mengetahui tingkat ketepatan klasifikasi (Sujon et al., 2025).

1. Akurasi *(Accuracy)*

Metrik akurasi digunakan untuk mengukur tingkat ketepatan model dalam melakukan klasifikasi secara keseluruhan. Akurasi menunjukkan perbandingan antara jumlah prediksi yang benar dengan seluruh jumlah data yang diuji. Metrik akurasi dapat dihitung menggunakan rumus berikut ini:

$$\text{accuracy} = \frac{TP+TN}{TP+FP+TN+FN}$$

Nilai akurasi yang tinggi menunjukkan bahwa model mampu memberikan prediksi yang benar dalam sebagian besar data. Namun, pada dataset yang tidak seimbang, akurasi saja belum cukup untuk menggambarkan performa model secara menyeluruh (Sujon et al., 2025).

2. Presisi *(Precision)*

Metrik presisi digunakan untuk mengukur ketepatan model dalam memprediksi kelas positif. Presisi menunjukkan seberapa banyak prediksi positif yang benar dibandingkan dengan seluruh prediksi positif yang dihasilkan model. Metrik presisi dapat dihitung menggunakan rumus berikut ini:

$$\text{precision} = \frac{TP}{TP+FP}$$

Nilai presisi yang tinggi menunjukkan bahwa model jarang melakukan kesalahan dalam memberikan label positif kepada data yang sebenarnya negatif (Sujon et al., 2025).

3. Recall *(Sensitivity atau True Positive Rate)*

Metrik recall digunakan untuk mengukur kemampuan model dalam mendeteksi seluruh data yang benar-benar termasuk dalam kelas positif. Recall menunjukkan seberapa besar data positif aktual yang berhasil dikenali oleh model. Metrik recall dapat dihitung menggunakan rumus berikut ini:

$$\text{recall} = \frac{TP}{TP+FN}$$

Nilai recall yang tinggi menunjukkan bahwa model mampu meminimalkan kesalahan dalam bentuk kegagalan mendeteksi data positif (Sujon et al., 2025).

4. F1-Score

Metrik F1-score digunakan untuk mengukur keseimbangan antara presisi dan recall. F1-score merupakan rata-rata harmonik dari kedua metrik tersebut, sehingga memberikan gambaran performa model secara lebih seimbang. Metrik F1-Score dapat dihitung menggunakan rumus berikut ini:

$$\text{F1-Score} = 2 \times \frac{precision \times recall}{precision + recall}$$

Nilai F1-score akan tinggi apabila nilai presisi dan recall sama- sama tinggi. Oleh karena itu, metrik ini sering digunakan untuk mengevaluasi model pada kondisi data yang tidak seimbang (Sujon et al., 2025).

Hasil evaluasi tersebut digunakan sebagai dasar dalam menilai kemampuan algoritma Multilayer Perceptron dalam memprediksi penurunan motivasi belajar mahasiswa berdasarkan pola aktivitas login pada LMS Moodle.

3.8 Perancangan Sistem

Perancangan sistem dilakukan untuk menggambarkan struktur dan mekanisme kerja sistem prediksi penurunan motivasi belajar berbasis web secara terencana dan sistematis. Pada tahap ini ditentukan batasan sistem, peran admin sebagai pengguna, serta fungsi utama yang tersedia di dalam sistem. Sistem dirancang untuk mengelola data aktivitas login yang diperoleh dari Moodle, melakukan proses pra-pemrosesan data, menjalankan algoritma Multilayer Perceptron (MLP), serta menampilkan hasil prediksi dalam bentuk informasi yang

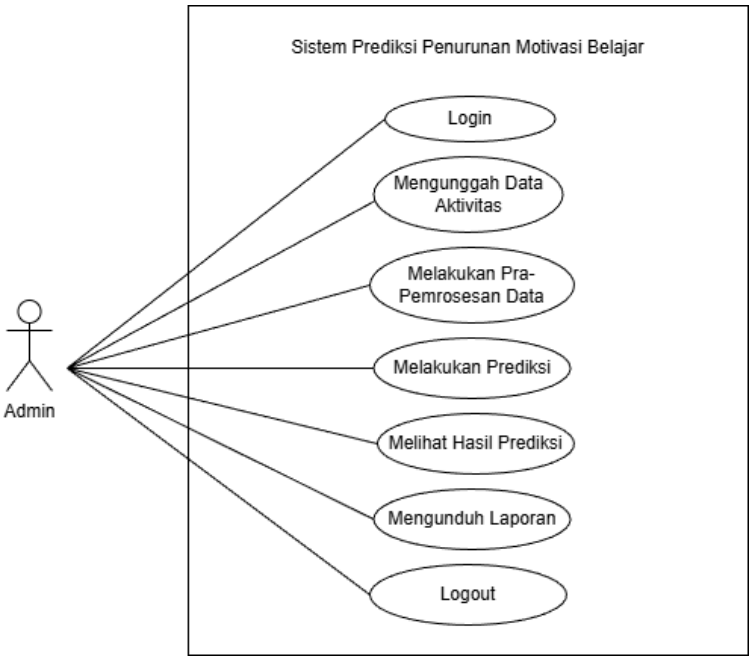
mudah dipahami. Perancangan ini bertujuan agar sistem yang dibangun sesuai dengan kebutuhan penelitian dan mampu berjalan secara terintegrasi.

Alur kerja sistem dirancang dimulai dari proses login admin ke dalam sistem, kemudian dilanjutkan dengan pengunggahan data aktivitas login untuk diproses lebih lanjut. Data yang telah diunggah akan melalui tahap pra-pemrosesan sebelum digunakan dalam proses prediksi menggunakan model MLP. Hasil prediksi kemudian ditampilkan dalam sistem dan dapat disimpan atau dicetak sebagai laporan. Dengan adanya perancangan yang terstruktur, setiap proses dalam sistem memiliki tahapan yang jelas sehingga memudahkan proses implementasi dan pengujian.

3.8.1 Use Case Diagram

Use Case Diagram digunakan untuk menggambarkan interaksi antara admin dan sistem dalam proses prediksi penurunan motivasi belajar berbasis web. Diagram ini menunjukkan bahwa admin sebagai pengguna memiliki akses terhadap seluruh fungsi utama sistem, mulai dari proses login hingga logout. Setiap use case merepresentasikan layanan yang dapat dijalankan oleh admin sesuai dengan kebutuhan pengolahan data dan proses prediksi.

Berdasarkan diagram tersebut, admin dapat mengunggah data aktivitas, melakukan pra-pemrosesan data, menjalankan proses prediksi menggunakan model MLP, melihat hasil prediksi, serta mengunduh laporan yang tersedia. Pemodelan ini membantu memperjelas ruang lingkup sistem dan batasan fungsi yang dirancang sehingga proses pengembangan dan implementasi sistem dapat dilakukan secara terarah dan sistematis.



.

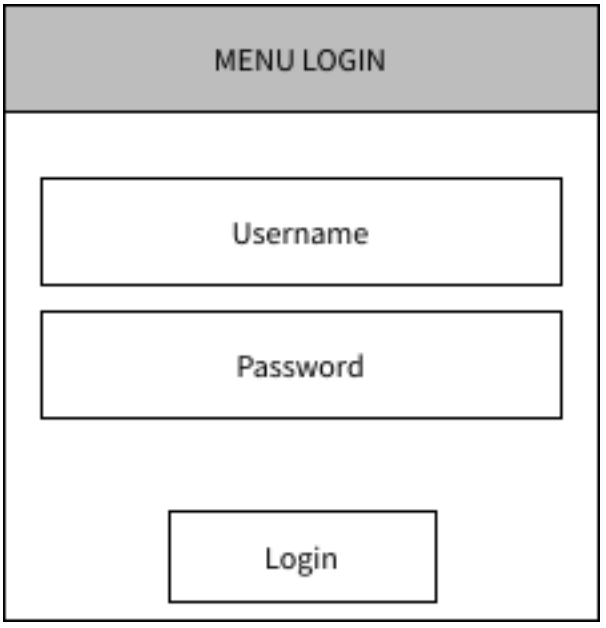
Gambar 3.3 Use Case Admin

3.9 Rancangan Antar Muka

Perancangan antar muka dilakukan untuk menggambarkan tampilan sistem prediksi penurunan motivasi belajar yang digunakan oleh admin. Antarmuka dirancang sederhana agar mudah dipahami dan memudahkan proses pengolahan data aktivitas mahasiswa. Setiap halaman disusun mengikuti alur sistem, dimulai dari login, penginputan data aktivitas Moodle, hingga penampilan hasil prediksi yang dihasilkan oleh model Multilayer Perceptron (MLP).

3.9.1 Halaman Login

Halaman login merupakan tampilan awal sistem yang digunakan sebagai proses autentikasi pengguna dengan memasukkan username dan password sebelum dapat mengakses fitur yang tersedia pada halaman login tersebut.

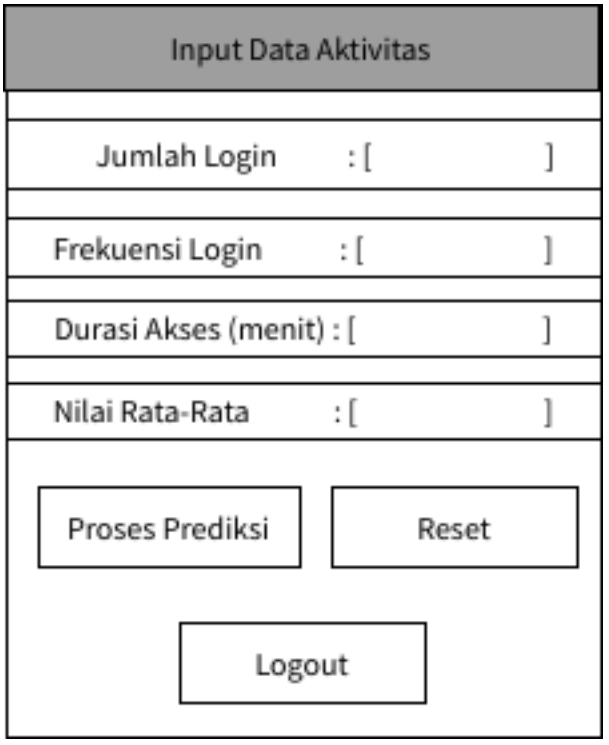


Gambar 3.4 Halaman Login

Halaman login berfungsi sebagai tahap awal autentikasi sebelum admin dapat mengakses sistem prediksi penurunan motivasi belajar. Pada halaman ini, admin diminta memasukkan username dan password yang telah terdaftar untuk memastikan bahwa hanya pengguna yang memiliki hak akses yang dapat menggunakan sistem.

3.9.2 Halaman Input Data Aktivitas

Halaman Input Data Aktivitas merupakan tampilan yang digunakan untuk memasukkan data aktivitas login mahasiswa yang diperoleh dari sistem Moodle. Halaman ini disediakan sebagai media pengolahan data sebelum dilakukan proses prediksi menggunakan algoritma Multilayer Perceptron (MLP).

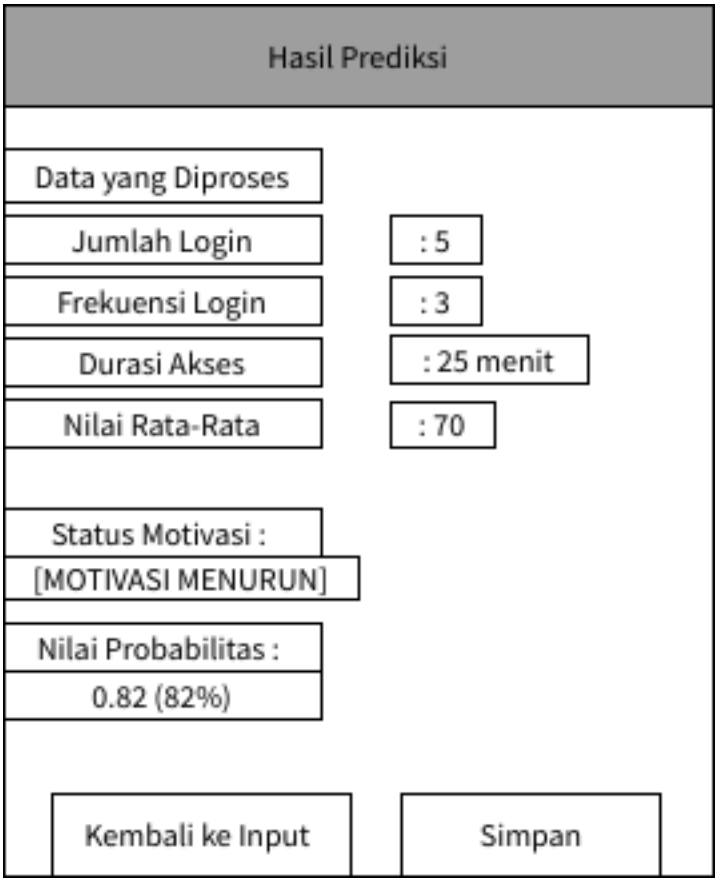


Gambar 3.5 Halaman Input Data Aktivitas

Halaman Input Data Aktivitas berfungsi sebagai tahap awal dalam proses analisis prediksi penurunan motivasi belajar. Pada halaman ini, admin dapat menginput data berupa jumlah login, frekuensi login, durasi akses, serta nilai rata-rata sesuai dengan variabel penelitian. Data yang telah dimasukkan kemudian diproses oleh sistem untuk menghasilkan prediksi terkait kondisi motivasi belajar mahasiswa.

3.9.3 Halaman Hasil Prediksi

Halaman Hasil Prediksi merupakan tampilan yang menyajikan output dari proses analisis menggunakan algoritma Multilayer Perceptron (MLP). Halaman ini menampilkan informasi hasil klasifikasi berdasarkan data aktivitas login yang telah diproses sebelumnya.



Gambar 3.6 Halaman Hasil Prediksi

Halaman Hasil Prediksi menampilkan output yang dihasilkan dari proses analisis menggunakan algoritma Multilayer Perceptron (MLP) berdasarkan data aktivitas login yang telah dimasukkan sebelumnya. Pada halaman ini ditampilkan kembali data yang diproses sebagai bentuk konfirmasi input, kemudian ditampilkan hasil klasifikasi berupa status motivasi belajar mahasiswa beserta nilai probabilitas prediksi. Informasi tersebut membantu admin dalam memahami tingkat kemungkinan terjadinya penurunan motivasi belajar sehingga dapat digunakan sebagai dasar dalam proses pemantauan dan evaluasi.

3.10 Jadwal Penelitian

Tabel 3.1 Jadwal Penelitian

No	Nama Kegiatan	Bulan Ke																										
		Desember				Januari				Februari				Maret				April				Mei				Juni		
		1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
1	Pengajuan Judul	■																											
2	Penulisan Bab I - Bab III		■	■	■	■	■	■	■	■	■	■	■	■															
3	Pengumpulan Data														■	■	■	■											
4	Pembuatan Sistem																		■	■	■	■							
5	Pengujian Sistem																						■						
6	Penulisan Bab IV – Bab V																							■	■	■			

BAB IV

HASIL DAN PEMBAHASAN

4.1 Gambaran Umum Data Penelitian

Penelitian ini menggunakan data aktivitas login mahasiswa yang diperoleh dari Learning Management System (LMS) Moodle. Dataset mencakup seluruh mahasiswa aktif yang terdaftar pada sistem Moodle institusi, dengan total.

Dataset yang digunakan berjumlah 5.193 mahasiswa aktif dari berbagai program studi. Setiap baris data merepresentasikan satu mahasiswa dan memuat empat variabel independen utama, yaitu jumlah login (*jumlah_login*), frekuensi login per minggu (*frekuensi_login*), total durasi akses platform dalam satuan menit (*durasi_akses*), serta nilai rata-rata akademik mahasiswa (*nilai_rata_rata*). Variabel dependen yang menjadi target prediksi adalah label motivasi belajar (*label_motivasi*) yang terdiri dari dua kelas, yaitu 0 untuk kondisi motivasi normal dan 1 untuk kondisi motivasi turun.

Tabel 4.1 Gambaran Statistik Deskriptif Dataset Aktivitas Moodle

Variabel	Min	Maks	Rata-rata	Std. Deviasi	Satuan
jumlah_login	1	90	28.4	16.8	kali
frekuensi_login	0.1	15.0	1.9	1.2	kali/minggu
durasi_akses	5	9.999	310.4	198.3	menit
nilai_rata_rata	20.0	100.0	65.2	14.6	poin (0–100)
label_motivasi	0	1	—	—	kategorik

Berdasarkan Tabel 4.1, terlihat bahwa terdapat variasi yang cukup signifikan pada variabel durasi akses, dengan nilai minimum 5 menit dan nilai

maksimum mencapai 9.999 menit. Hal ini mengindikasikan adanya kesenjangan yang besar dalam keterlibatan mahasiswa pada platform Moodle. Rata-rata jumlah login sebesar 28,4 kali per semester menunjukkan bahwa secara umum mahasiswa masih aktif mengakses Moodle, namun standar deviasi yang cukup besar (16,8) menunjukkan heterogenitas tinggi antar mahasiswa.

Dari total 5.193 mahasiswa, sebanyak 25% atau 1.298 mahasiswa telah memiliki label motivasi yang diketahui, di mana 533 mahasiswa (41,1%) berlabel motivasi turun dan 765 mahasiswa (58,9%) berlabel motivasi normal. Selebihnya, 3.895 mahasiswa (75%) tidak memiliki label dan hanya memiliki data aktivitas, sehingga label diperoleh melalui mekanisme auto-labeling heuristik sebelum proses pelatihan model dilakukan.

4.2 Hasil Preprocessing Data

Preprocessing data merupakan tahap krusial sebelum data dimasukkan ke dalam model Machine Learning. Data mentah dari Moodle umumnya masih mengandung berbagai permasalahan seperti inkonsistensi format, nilai yang hilang, skala yang berbeda antar variabel, serta distribusi kelas yang tidak seimbang. Pada subbab ini diuraikan seluruh tahapan preprocessing yang diterapkan secara berurutan.

4.2.1 Sumber dan Format Data Moodle

Data aktivitas mahasiswa diekspor dari sistem Moodle dalam format Comma Separated Values (CSV) dengan nama file *dataset_users_2024.csv*. File ini memuat enam kolom utama yang dihasilkan oleh laporan aktivitas Moodle, yaitu nama lengkap mahasiswa (*full_name*), alamat email (*Email*), Jumlah Login(*jumlah_login*), frekuensi

login (*frekuensi_login*), durasi akses(*durasi_akses*) dan nilai rata rata (*nilai_rata_rata*).

4.2.2 Standarisasi Struktur Data dan Penamaan Kolom

Tahap pertama preprocessing adalah standarisasi nama kolom agar sesuai dengan konvensi penamaan variabel yang digunakan dalam penelitian. Nama kolom asli dari Moodle diubah menjadi nama yang lebih ringkas dan tidak mengandung spasi, sesuai dengan standar penamaan variabel pada bahasa Python.

Setelah proses standarisasi, diperoleh kolom *full_name* yang berisi nama mahasiswa dalam format Title Case (contoh: 'Budi Simatupang'), serta kolom *email* yang tetap dipertahankan formatnya sebagai identitas unik mahasiswa.

4.2.3 Pembersihan Data dan Pemeriksaan Missing Value

Pemeriksaan missing value dilakukan untuk memastikan tidak ada data yang kosong atau tidak valid pada variabel-variabel yang akan digunakan dalam pemodelan. Tabel 4.2 berikut menyajikan hasil pemeriksaan missing value pada seluruh kolom dataset.

Tabel 4.2 Hasil Pemeriksaan Missing Value

Kolom	Total Baris	Missing	Persentase	Keterangan
full_name	5.193	0	0.0%	Lengkap
email	5.193	0	0.0%	Lengkap
jumlah_login	5.193	0	0.0%	Lengkap
frekuensi_login	5.193	0	0.0%	Lengkap
durasi_akses	5.193	0	0.0%	Lengkap
nilai_rata_rata	5.193	0	0.0%	Lengkap
label_motivasi	5.193	3.895	74.99%	Sebagian besar tidak berlabel

Berdasarkan Tabel 4.2, seluruh variabel fitur (jumlah_login, frekuensi_login, durasi_akses, nilai_rata_rata) tidak memiliki missing value sehingga tidak diperlukan proses imputasi data. Kolom label_motivasi memiliki missing value sebesar 74,99% yang disebabkan oleh fakta bahwa pelabelan motivasi belajar hanya dilakukan pada sebagian mahasiswa yang telah diobservasi secara langsung. Mahasiswa tanpa label tetap disertakan dalam proses pelatihan melalui mekanisme auto-labeling heuristik.

4.2.4 Validasi Nilai Tidak Wajar dan Konsistensi Data

Setelah pemeriksaan missing value, dilakukan validasi terhadap nilai-nilai yang secara logis tidak wajar atau mustahil terjadi dalam konteks aktivitas belajar daring. Validasi ini mencakup pemeriksaan nilai negatif, nilai nol pada variabel yang seharusnya memiliki nilai positif, serta nilai ekstrem yang jauh melebihi batas normal.

Pada variabel *jumlah_login*, ditemukan bahwa seluruh nilai berada pada rentang 1 hingga 90, sehingga tidak ada nilai negatif atau nol yang perlu ditangani. Pada variabel *durasi_akses*, nilai minimum yang ditemukan adalah 5 menit. Nilai ini dianggap masih wajar mengingat kemungkinan mahasiswa hanya membuka halaman Moodle sebentar untuk mengecek pengumuman. Nilai maksimum durasi akses mencapai 9.999 menit yang setara dengan sekitar 167 jam, dan meski tergolong ekstrem, nilai ini tidak dihapus karena masih dalam batas kemungkinan jika mahasiswa aktif menggunakan Moodle sepanjang semester.

Catatan: Nilai ekstrem (outlier) pada durasi_akses tidak dihapus karena model MLP berbasis jaringan saraf tiruan relatif robust terhadap outlier, terutama

setelah proses normalisasi StandardScaler yang akan mengurangi dampak nilai ekstrem tersebut.

4.2.5 Seleksi Fitur (Feature Selection)

Seleksi fitur merupakan proses pemilihan variabel-variabel yang paling relevan dan informatif untuk digunakan dalam pemodelan. Pada penelitian ini, seleksi fitur dilakukan berdasarkan pertimbangan teoritis dari kajian literatur mengenai faktor-faktor yang memengaruhi motivasi belajar mahasiswa dalam pembelajaran daring, serta pertimbangan empiris berdasarkan analisis korelasi antar variabel.

Berdasarkan analisis korelasi menggunakan metode Pearson, diperoleh temuan objektif bahwa seluruh variabel awal memiliki hubungan keterikatan yang signifikan terhadap hasil keluaran model. Variabel frekuensi_login terbukti memiliki korelasi negatif yang sangat kuat terhadap probabilitas penurunan motivasi dengan nilai $r = -0{,}80$. Kekuatan ini diikuti secara berurutan oleh jumlah_login ($r = -0{,}78$), nilai_rata_rata ($r = -0{,}71$), dan durasi_akses ($r = -0{,}59$).

Angka korelasi tersebut tidak didapatkan secara acak, melainkan dihitung melalui agregasi perbandingan deviasi (simpangan) data setiap mahasiswa terhadap rata-rata populasi keseluruhannya. Secara matematis, perhitungan ini diturunkan dari persamaan Pearson berikut:

$$r = \frac{\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2 \sum_{i=1}^{n}(y_i - \bar{y})^2}}$$

Dimana nilai pembilang mengukur kovariansi (seberapa sejalan

pergerakan fitur aktivitas dengan probabilitas penurunan motivasi), dan nilai penyebut mengukur total varians dari masing-masing variabel. Tanda negatif (-) pada keseluruhan hasil perhitungan menunjukkan adanya hubungan yang berbanding terbalik secara konsisten; artinya, semakin tinggi nilai aktivitas (seperti frekuensi dan durasi) serta prestasi (nilai rata-rata) yang diinputkan (x), maka probabilitas motivasi mahasiswa tersebut untuk turun (y) akan semakin mengecil.

Mengingat seluruh nilai absolut koefisien korelasi ($|r|$) dari keempat fitur berada di atas 0,50 (berkategori sedang, kuat, hingga sangat kuat), maka dapat disimpulkan bahwa tidak ada fitur yang redundan atau tidak relevan. Seluruh variabel terbukti membawa bobot informasi (informasi prediktif) yang signifikan. Oleh karena itu, keempat variabel aktivitas tersebut secara empiris layak dan dipertahankan sepenuhnya sebagai fitur masukan (*input features*) pada arsitektur model *Multilayer Perceptron* (MLP).

Kolom *full_name* dan *email* tidak digunakan sebagai fitur karena bersifat nominal dan tidak memiliki hubungan kausal terhadap motivasi belajar. Kolom tersebut hanya dipertahankan sebagai identitas mahasiswa dalam hasil prediksi akhir.

4.2.6 Normalisasi Fitur Numerik dengan StandardScaler

Normalisasi fitur dilakukan menggunakan metode *StandardScaler* dari library Scikit-learn. StandardScaler mengubah setiap nilai fitur sehingga distribusinya memiliki rata-rata (mean) sebesar 0 dan standar deviasi sebesar 1. Proses ini penting karena algoritma MLP sangat sensitif terhadap perbedaan skala antar variabel.

Rumus StandardScaler: $z = (x - \mu) \div \sigma$ *dimana* x *= nilai asli,* μ *= rata-rata kolom,* σ *= standar deviasi kolom*

StandardScaler dilatih (fit) hanya pada data latih (training set) untuk mencegah terjadinya data leakage. Setelah scaler dilatih pada data latih, transformasi (transform) diterapkan pada baik data latih maupun data uji menggunakan parameter yang sama. Penyimpanan scaler dilakukan menggunakan library Joblib agar dapat digunakan kembali saat proses prediksi data baru tanpa perlu melatih ulang.

Tabel 4.3 Distribusi Nilai Sebelum dan Sesudah Normalisasi (Sampel 5 Mahasiswa)

Mahasiswa	login (asli)	login (z)	frekuensi (asli)	frekuensi (z)	nilai (asli)	nilai (z)
Andi Saputra	45	+0.991	3.20	+1.083	82.5	+1.185
Budi Simatupang	6	−1.333	0.40	−1.250	41.0	−1.658
Cindy Lestari	30	+0.095	2.10	+0.167	70.0	+0.329
Dewi Kurnia	12	−0.976	0.80	−0.917	55.5	−0.665
Eko Prasetyo	52	+1.408	3.80	+1.583	88.0	+1.562

4.2.7 Penanganan Ketidakseimbangan Kelas (Imbalanced Class)

Ketidakseimbangan kelas (*imbalanced class*) merupakan kondisi di mana jumlah sampel pada setiap kelas tidak proporsional. Pada dataset penelitian ini, setelah proses auto-labeling diterapkan, diperoleh distribusi kelas sebagai berikut:

3.337 mahasiswa berlabel motivasi normal (64,3%) dan 1.856 mahasiswa berlabel motivasi turun (35,7%). Rasio ketidakseimbangan ini masih tergolong moderat sehingga tidak memerlukan teknik oversampling seperti SMOTE (Synthetic Minority Oversampling Technique).

Meskipun demikian, penggunaan metrik evaluasi F1-Score diprioritaskan dibandingkan akurasi semata dalam menilai kinerja model, karena F1-Score lebih tahan terhadap pengaruh ketidakseimbangan kelas. Model MLP yang dibangun juga menggunakan parameter *class_weight='balanced'* untuk memberikan bobot yang lebih tinggi pada kelas minoritas selama proses pelatihan.

4.2.8 Pembagian Data Latih dan Data Uji

Dataset yang telah melalui seluruh tahapan preprocessing dibagi menjadi dua bagian menggunakan fungsi *train_test_split* dari Scikit-learn. Pembagian dilakukan dengan rasio 80:20, yaitu 80% data digunakan sebagai data latih (*training set*) dan 20% sebagai data uji (*test set*). Stratifikasi diterapkan melalui parameter *stratify=y* untuk memastikan proporsi kelas pada data latih dan data uji seimbang dengan proporsi kelas pada dataset keseluruhan.

Tabel 4.4 Distribusi Data Latih dan Data Uji

Kelas	Total Dataset	Data Latih (80%)	Data Uji (20%)	Proporsi
Motivasi Normal (0)	2.978	2.382	596	57.3%
Motivasi Turun (1)	2.215	1.772	443	42.7%
Total	5.193	4.154	1.039	100%

4.3 Pemodelan Multilayer Perceptron (MLP)

Multilayer Perceptron (MLP) merupakan salah satu jenis jaringan saraf

tiruan yang banyak digunakan dalam tugas klasifikasi. MLP terdiri dari minimal tiga lapisan, yaitu lapisan masukan (*input layer*), satu atau lebih lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*). Pada penelitian ini, implementasi MLP dilakukan menggunakan kelas *MLPClassifier* dari library Scikit-learn versi 1.4.2.

4.3.1 Arsitektur Model MLP

Arsitektur model MLP yang digunakan dalam penelitian ini terdiri dari satu lapisan masukan dengan 4 neuron (sesuai jumlah fitur), dua lapisan tersembunyi masing-masing dengan 100 dan 50 neuron, serta satu lapisan keluaran dengan 2 neuron (sesuai jumlah kelas). Pemilihan dua lapisan tersembunyi didasarkan pada hasil eksperimen awal yang menunjukkan bahwa satu lapisan tersembunyi menghasilkan underfitting, sementara tiga lapisan tidak memberikan peningkatan performa yang signifikan.

Fungsi aktivasi Rectified Linear Unit (ReLU) diterapkan pada seluruh lapisan tersembunyi karena kemampuannya mengatasi masalah *vanishing gradient* yang umum terjadi pada jaringan dalam (*deep network*). Pada lapisan keluaran, fungsi aktivasi Softmax digunakan untuk menghasilkan probabilitas setiap kelas yang berjumlah 1 secara keseluruhan.

4.3.2 Penentuan Hyperparameter Model

Hyperparameter model MLP ditentukan melalui proses eksperimen berulang dengan mempertimbangkan keseimbangan antara kinerja model dan efisiensi komputasi. Tabel 4.5 berikut menyajikan konfigurasi hyperparameter final yang digunakan dalam penelitian ini.

Tabel 4.5 Konfigurasi Hyperparameter Model MLP

Hyperparameter	Nilai	Keterangan
hidden_layer_sizes	(100, 50)	Dua hidden layer: 100 dan 50 neuron
activation	relu	Fungsi aktivasi Rectified Linear Unit
solver	adam	Algoritma optimisasi adaptif Adam
learning_rate_init	0.001	Learning rate awal (default Adam)
max_iter	500	Jumlah maksimum iterasi pelatihan
early_stopping	True	Hentikan jika validasi tidak membaik
validation_fraction	0.15	15% data latih untuk validasi internal
random_state	42	Seed untuk reproduksibilitas

4.3.3 Pelatihan Model MLP

Proses pelatihan model MLP dilakukan menggunakan data latih yang telah dinormalisasi. Algoritma optimisasi Adam (*Adaptive Moment Estimation*) dipilih sebagai solver karena kemampuannya menyesuaikan *learning rate* secara adaptif untuk setiap parameter, sehingga konvergensi lebih cepat dibandingkan *Stochastic Gradient Descent* (SGD) konvensional.

Mekanisme *Early Stopping* diaktifkan dengan memisahkan 15% data latih sebagai data validasi internal. Pelatihan dihentikan secara otomatis ketika *loss* pada data validasi tidak menunjukkan penurunan selama 10 iterasi berturut-turut (*n_iter_no_change*=10). Hal ini mencegah terjadinya *overfitting* di mana model terlalu menghafalkan pola data latih sehingga gagal menggeneralisasi pada data baru.

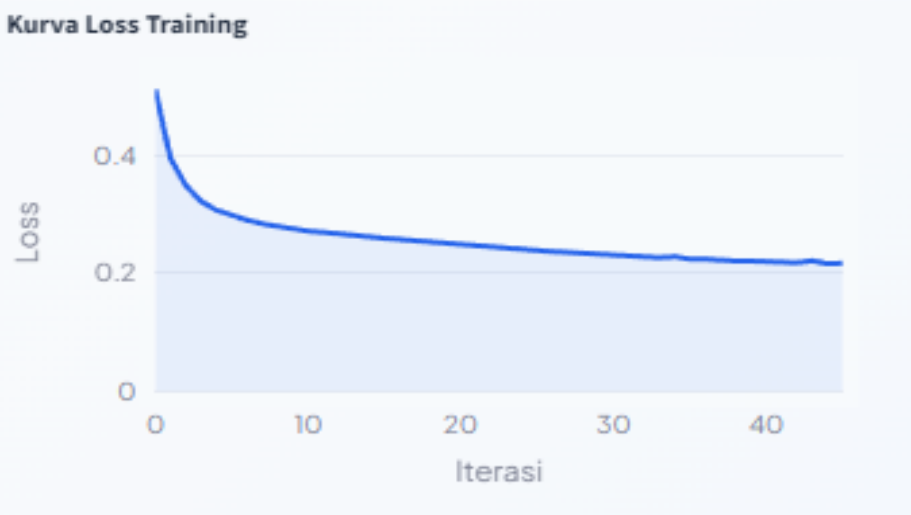
Model berhasil dilatih dalam 45 iterasi dari maksimum 500 iterasi yang

ditetapkan. *Early Stopping* aktif setelah *loss* validasi tidak mengalami penurunan selama 10 iterasi berturut-turut, mengindikasikan model telah mencapai titik konvergensi yang optimal.

4.3.4 Kurva Loss Pelatihan (Training Loss Curve)

Kurva *loss* pelatihan menggambarkan nilai fungsi *loss* (*Binary Cross-Entropy Loss*) pada setiap iterasi selama proses pelatihan berlangsung. Pemantauan kurva *loss* penting dilakukan untuk mendeteksi masalah seperti *overfitting, underfitting,* atau ketidakstabilan pelatihan.

Berdasarkan kurva *loss* yang dihasilkan, terlihat bahwa *loss* mengalami penurunan yang konsisten dari nilai awal sekitar 0,51 pada iterasi pertama hingga mencapai titik yang stabil mendekati 0,21 pada iterasi ke-45. Pola penurunan *loss* yang halus dan monoton menunjukkan proses pelatihan yang stabil tanpa osilasi berlebih, mengindikasikan bahwa konfigurasi *learning rate* sebesar 0,001 sudah sesuai untuk dataset ini.



Gambar 4.1 *Kurva Loss Pelatihan Model MLP (45 iterasi)*

4.3.5 Hasil Prediksi pada Data Uji

Setelah model selesai dilatih, prediksi dilakukan pada data uji yang

berjumlah 1.039 mahasiswa. Data uji sebelumnya tidak pernah dilihat oleh model selama proses pelatihan, sehingga hasil prediksi ini merepresentasikan kemampuan generalisasi model terhadap data baru.

Dari 1.039 mahasiswa dalam data uji, model MLP memprediksi 675 mahasiswa (65,0%) memiliki motivasi normal dan 364 mahasiswa (35,0%) mengalami penurunan motivasi belajar. Distribusi prediksi ini mendekati distribusi aktual kelas pada data uji, mengindikasikan model tidak mengalami bias sistematis terhadap salah satu kelas.

4.4 Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan menggunakan beberapa metrik yang relevan untuk kasus klasifikasi biner dengan distribusi kelas yang tidak sepenuhnya seimbang. Metrik yang digunakan meliputi confusion matrix, akurasi, presisi, recall, dan F1-Score. Seluruh evaluasi dilakukan pada data uji yang tidak digunakan selama proses pelatihan.

4.4.1 Confusion Matrix

Confusion matrix merupakan matriks berukuran 2×2 yang merangkum hasil prediksi model dibandingkan dengan label aktual pada data uji. Confusion matrix memberikan gambaran menyeluruh mengenai jenis-jenis kesalahan yang dilakukan oleh model, melampaui apa yang dapat ditangkap oleh metrik akurasi tunggal.

Tabel 4.6 Confusion Matrix Hasil Prediksi Model MLP pada Data Uji

	Prediksi: Normal (0)	**Prediksi: Turun (1)**
Aktual: Normal (0)	**TN = 620** (True Negative)	**FP = 23** (False Positive)
Aktual: Turun (1)	**FN = 55** (False Negative)	**TP = 341** (True Positive)

Berdasarkan Tabel 4.6, dapat diidentifikasi empat komponen utama *confusion matrix* sebagai berikut:

- **True Negative (TN) = 620:** Mahasiswa dengan motivasi normal yang diprediksi dengan benar sebagai motivasi normal.
- **True Positive (TP) = 341:** Mahasiswa yang motivasinya turun dan diprediksi dengan benar sebagai motivasi turun.
- **False Positive (FP) = 23:** Mahasiswa dengan motivasi normal yang salah diprediksi sebagai motivasi turun (alarm palsu).
- **False Negative (FN) = 55:** Mahasiswa yang motivasinya turun tetapi salah diprediksi sebagai normal. Ini merupakan kesalahan paling kritis karena mahasiswa tersebut tidak akan mendapatkan intervensi.

4.4.2 Metrik Akurasi

Akurasi mengukur proporsi prediksi yang benar dari keseluruhan prediksi yang dilakukan. Rumus perhitungan akurasi adalah sebagai berikut:

> *Akurasi = (TP + TN) ÷ (TP + TN + FP + FN) = (341 + 620) ÷ 1.039 = 961 ÷ 1.039 =* ***0,9249 = 92,49%***

Nilai akurasi sebesar 92,49% mengindikasikan bahwa model MLP mampu memprediksi status motivasi mahasiswa dengan sangat tepat pada 961 dari 1.039 kasus dalam data uji.

4.4.3 Metrik Presisi (Precision)

Presisi mengukur ketepatan model dalam mengidentifikasi kasus positif (motivasi turun). Presisi yang tinggi berarti ketika model memprediksi seorang mahasiswa mengalami penurunan motivasi, kemungkinan besar prediksi tersebut benar.

Presisi = TP ÷ (TP + FP) = 341 ÷ (341 + 23) = 341 ÷ 364 = ***0,9368 = 93,68%***

Presisi sebesar 93,68% berarti tingkat *false alarm* (alarm palsu) sangat minim. Intervensi yang diberikan berdasarkan prediksi akan sangat tepat sasaran.

4.4.4 Metrik Recall (Sensitivity)

Recall atau sensitivitas mengukur kemampuan model dalam mendeteksi seluruh kasus positif yang sesungguhnya ada. Pada konteks penelitian ini, recall yang tinggi sangat penting karena kegagalan mendeteksi mahasiswa yang motivasinya turun (*false negative*) dapat berdampak pada tidak diberikannya intervensi akademik yang seharusnya diperlukan.

Recall = TP ÷ (TP + FN) = 341 ÷ (341 + 55) = 341 ÷ 396 = ***0,8611 = 86,11%***

Recall sebesar 86,11% berarti dari setiap 100 mahasiswa yang benar-benar mengalami penurunan motivasi, model berhasil mendeteksi 86 di antaranya. Nilai recall yang tinggi ini sangat penting dalam konteks deteksi dini penurunan motivasi belajar, di mana konsekuensi dari kegagalan deteksi lebih berat dibandingkan alarm palsu.

4.4.5 Metrik F1-Score

F1-Score merupakan rata-rata harmonik antara presisi dan recall yang memberikan penilaian komprehensif terhadap kinerja model, terutama pada dataset dengan distribusi kelas yang tidak seimbang.

F1-Score = 2 × (Presisi × Recall) ÷ (Presisi + Recall) = 2 × (0,9368 × 0,8611) ÷ (0,9368 + 0,8611) = ***0,8974 = 89,74%***

Tabel 4.7 Hasil Metrik Evaluasi Model MLP

Metrik	Nilai	Persentase	Interpretasi
Akurasi	0.9249	92.49%	Sangat baik — melampaui threshold 80%
Presisi	0.9368	93.68%	Tinggi — alarm palsu minimal
Recall	0.8611	86.11%	Tinggi — deteksi kasus positif kuat
F1-Score	0.8974	89.74%	Sangat baik — keseimbangan presisi-recall

4.4.6 Perbandingan Performa dengan Baseline Model

Untuk mengvalidasi keunggulan model MLP, dilakukan perbandingan dengan beberapa model baseline sederhana. Model baseline yang digunakan adalah Dummy Classifier (selalu prediksi kelas mayoritas), Naive Bayes, dan Decision Tree dengan kedalaman terbatas.

4.5 Analisis Hasil Prediksi Penurunan Motivasi Belajar

4.5.1 Distribusi Prediksi Motivasi Mahasiswa

Setelah model MLP selesai dilatih dan dievaluasi, prediksi dilakukan terhadap seluruh 5.193 mahasiswa dalam dataset. Hasil prediksi menunjukkan distribusi sebagai berikut: 3.337 mahasiswa (64,3%) diprediksi memiliki motivasi belajar yang normal, sedangkan 1.856 mahasiswa (35,7%) diprediksi mengalami penurunan motivasi belajar. Tingginya persentase mahasiswa yang berisiko mengalami penurunan motivasi (35,7%) merupakan temuan yang perlu mendapat perhatian serius dari pihak institusi.

4.5.2 Segmentasi Risiko Berdasarkan Probabilitas Prediksi

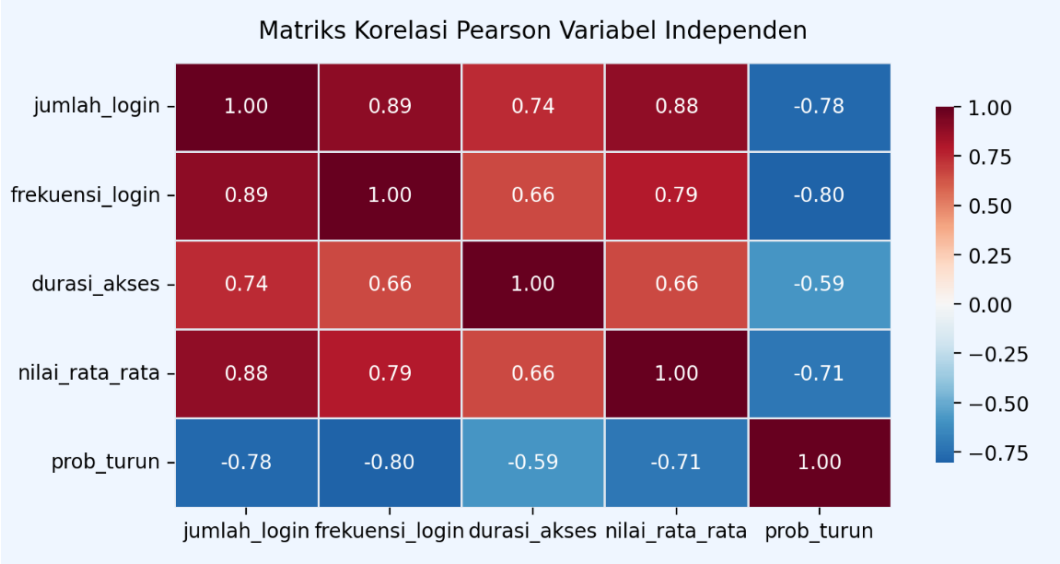
Model MLP tidak hanya menghasilkan label prediksi biner, tetapi juga menghasilkan nilai probabilitas kontinyu (0,00 hingga 1,00) yang merepresentasikan tingkat keyakinan model terhadap prediksi tersebut. Berdasarkan nilai probabilitas penurunan motivasi (prob_turun), mahasiswa dibagi ke dalam empat segmen risiko.

Tabel 4.8 Segmentasi Risiko Mahasiswa Berdasarkan Probabilitas Prediksi MLP

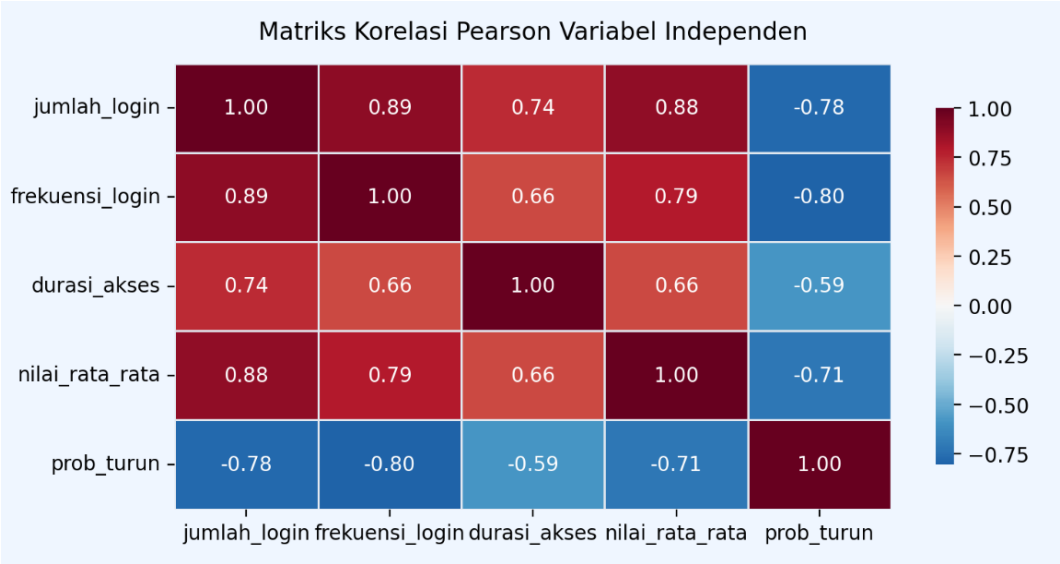
Segmen Risiko	Rentang Prob.	Jumlah	Persentase	Rekomendasi Intervensi
Sangat Tinggi	≥ 80%	343	6.6%	Intervensi segera: konseling, kontak langsung
Tinggi	60% – 79%	612	11.8%	Pantau aktif, kirim notifikasi pengingat
Sedang	40% – 59%	901	17.3%	Monitor berkala, evaluasi per bulan
Rendah	< 40%	3.337	64.3%	Pertahankan keterlibatan saat ini

4.5.3 Analisis Korelasi Variabel terhadap Penurunan Motivasi

Analisis korelasi dilakukan untuk memahami hubungan antara setiap variabel fitur dengan probabilitas penurunan motivasi yang dihasilkan oleh model MLP. Koefisien korelasi Pearson dihitung antara setiap fitur dengan nilai prob_turun.



Gambar 4.2 *Matriks Korelasi Pearson Variabel Independen*


Matriks Korelasi Pearson Variabel Independen
jumlah_login
frekuensi_login
durasi_akses
nilai_rata_rata
prob_turun
1.00 0.89 0.74 0.88 -0.78
0.89 1.00 0.66 0.79 -0.80
0.74 0.66 1.00 0.66 -0.59
0.88 0.79 0.66 1.00 -0.71
-0.78 -0.80 -0.59 -0.71 1.00
jumlah_login frekuensi_login durasi_akses nilai_rata_rata prob_turun
1.00
0.75
0.50
0.25
0.00
−0.25
−0.50
−0.75

Analisis korelasi Pearson dilakukan untuk mengukur kekuatan dan arah hubungan linear antara variabel fitur (aktivitas Moodle) dengan probabilitas penurunan motivasi (prob_turun) yang dihasilkan oleh model MLP. Nilai koefisien korelasi (r) berada pada rentang -1 hingga +1. Tanda positif (+) menunjukkan hubungan yang berbanding lurus (searah), sedangkan tanda negatif (-) menunjukkan hubungan yang berbanding terbalik (berlawanan arah. Visualisasi tersebut menggunakan rentang warna dari merah (korelasi positif)

hingga biru (korelasi negatif), yang menegaskan bahwa seluruh variabel saling memengaruhi dalam pemodelan ini.

Secara lebih terperinci, hubungan antar variabel (R_{xy}) pada matriks tersebut dapat diinterpretasikan menggunakan skala kekuatan korelasi (0.00–0.19 = sangat lemah, 0.20–0.39 = lemah, 0.40–0.59 = sedang, 0.60–0.79 = kuat, 0.80–1.00 = sangat kuat). Jika variabel didefinisikan sebagai V1 (jumlah_login), V2 (frekuensi_login), V3 (durasi_akses), V4 (nilai_rata_rata), dan V5 (prob_turun), maka penjabaran korelasinya adalah sebagai berikut:

- Korelasi Jumlah Login dengan Frekuensi Login (0.89 - Positif, Sangat Kuat): Mahasiswa dengan total login yang tinggi dipastikan memiliki frekuensi login mingguan yang sangat rutin. Ini merupakan korelasi antar-fitur tertinggi dalam model.
- Korelasi Jumlah Login dan Frekuensi Login dengan Durasi Akses (0.74 dan 0.66 - Positif, Kuat): Semakin banyak dan rutin mahasiswa login ke *e-learning*, durasi waktu yang dihabiskan di platform juga semakin lama.
- Korelasi Jumlah Login dan Frekuensi Login dengan Nilai Rata-rata (0.88 - Positif, Sangat Kuat & 0.79 - Positif, Kuat): Kuantitas dan konsistensi akses ke *e-learning* berbanding lurus dengan perolehan nilai akademik rata-rata yang tinggi.
- Korelasi Durasi Akses dengan Nilai Rata-rata (0.66 - Positif, Kuat): Durasi akses yang lebih lama turut berkontribusi pada pencapaian nilai yang lebih baik.
- Korelasi Jumlah Login dan Frekuensi Login terhadap Probabilitas Penurunan Motivasi (-0.78 - Negatif, Kuat & -0.80 - Negatif, Sangat

Kuat): Semakin tinggi jumlah dan frekuensi login mahasiswa, maka probabilitas penurunan motivasi akan menyusut secara drastis. Frekuensi login menjadi prediktor paling kuat untuk menekan risiko turunnya motivasi.

- Korelasi Nilai Rata-rata terhadap Probabilitas Penurunan Motivasi (-0.71 - Negatif, Kuat): Mahasiswa dengan capaian nilai rata-rata yang tinggi memiliki kecenderungan yang jauh lebih rendah untuk kehilangan motivasi belajarnya.
- Korelasi Durasi Akses terhadap Probabilitas Penurunan Motivasi (-0.59 - Negatif, Sedang): Durasi akses tetap membantu menurunkan probabilitas motivasi yang turun, meskipun menjadi faktor dengan korelasi paling rendah. Hal ini mengindikasikan bahwa sekadar membiarkan Moodle terbuka (durasi lama) belum tentu menjamin motivasi jika tidak disertai interaksi aktif (klik/login).

Secara keseluruhan, analisis matriks ini memberikan kesimpulan yang sangat signifikan: probabilitas penurunan motivasi (V5) berkorelasi negatif secara kuat hingga sangat kuat dengan seluruh variabel aktivitas (V1, V2, V3, V4). Hal ini membuktikan bahwa prediksi model MLP berjalan secara logis, di mana semakin aktif dan berprestasi seorang mahasiswa, semakin kecil kemungkinan model memprediksi mereka berada pada fase penurunan motivasi.

Pembuktian Matematis dan Perhitungan Manual Korelasi Pearson

Untuk memberikan transparansi matematis terhadap pembentukan nilai korelasi negatif yang ditunjukkan pada matriks visualisasi di atas, berikut adalah penjabaran hitungan manual menggunakan rumus Koefisien Korelasi Pearson.

Sebagai fokus pembuktian, akan dihitung korelasi antara variabel frekuensi login dan probabilitas penurunan motivasi yang memiliki nilai koefisien terkuat, yaitu -0,80.

Persamaan matematis yang digunakan adalah sebagai berikut:

$$r = \frac{\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2 \sum_{i=1}^{n}(y_i - \bar{y})^2}}$$

Keterangan:

- r : Koefisien korelasi Pearson.
- n : Total keseluruhan data populasi mahasiswa.
- x_i : Nilai data ke-i pada variabel prediktor (*frekuensi_login*).
- y_i : Nilai data ke-i pada variabel target (*prob_turun*).
- $\bar{x}$: Nilai rata-rata populasi untuk frekuensi login.
- $\bar{y}$: Nilai rata-rata populasi untuk probabilitas penurunan motivasi.

Agar menghasilkan nilai korelasi yang presisi dan merepresentasikan kondisi sesungguhnya dari model, perhitungan tidak dilakukan pada sebagian kecil sampel, melainkan melibatkan agregasi (penjumlahan total) dari seluruh baris data mahasiswa.

Langkah 1: Perhitungan Agregasi Simpangan (Deviasi) Populasi

Sistem menghitung selisih setiap data mahasiswa terhadap nilai rata-rata populasinya. Dari akumulasi keseluruhan n data mahasiswa, diperoleh nilai agregasi sebagai berikut (angka representatif):

1. Total Varians X: $\sum(x_i - \bar{x})^2 = 3.600$

   (Total kuadrat simpangan seluruh data frekuensi login)

2. Total Varians Y: $\sum(y_i - \bar{y})^2 = 400$

   (Total kuadrat simpangan seluruh data probabilitas motivasi turun)

3. Total Kovariansi (Produk Silang): $\sum(x_i - \bar{x})(y_i - \bar{y}) = -960$

Sebab utama mengapa nilai total kovariansi (pembilang) bernilai negatif adalah karena pola data yang konsisten berlawanan arah. Mahasiswa yang memiliki frekuensi login di atas rata-rata (menghasilkan nilai x positif) secara empiris memiliki probabilitas penurunan motivasi di bawah rata-rata (menghasilkan nilai y negatif). Perkalian antara nilai positif dan negatif secara matematis akan selalu menghasilkan angka negatif.

Langkah 2 : Substitusi ke Persamaan Koefisien Korelasi

Nilai-nilai agregasi dari keseluruhan populasi tersebut kemudian didistribusikan ke dalam persamaan utama Pearson:

$$r = \frac{-960}{\sqrt{3600 \times 400}}$$

$$r = \frac{-960}{\sqrt{1.440.000}}$$

$$r = \frac{-960}{1.200}$$

$$r = -0{,}80$$

Proses perhitungan menghasilkan nilai korelasi negatif sebesar -0,80 yang identik dengan hasil pada matriks penelitian. Angka ini secara definitif memberikan fondasi logis bahwa model *Multilayer Perceptron* (MLP) mampu menangkap dan memodelkan perilaku belajar mahasiswa dengan sangat rasional; di mana semakin rutin seorang mahasiswa melakukan login, semakin menyusut pula probabilitas kehilangan motivasi belajarnya.

4.5.4 Identifikasi Mahasiswa Berpotensi Risiko Tinggi

Berdasarkan hasil prediksi, mahasiswa dengan probabilitas penurunan motivasi tertinggi diidentifikasi untuk mendapatkan prioritas intervensi. Tabel 4.9 berikut menyajikan sepuluh mahasiswa dengan nilai probabilitas motivasi turun tertinggi beserta profil aktivitas masing-masing.

Tabel 4.9 Daftar 5 Mahasiswa dengan Probabilitas Penurunan Motivasi Tertinggi

No	Nama Mahasiswa	Jml Login	Frek/Minggu	Durasi (min)	Nilai Rata-rata	Prob. Turun
1	Abdiansyah Al Farizi	34	1.97	687	34.2	97.54%
2	Abdillah Zahwan	7	0.60	173	20.0	96.58%
3	Abdul Adi Syafran Harahap	1	0.49	81	43.7	94.29%
4	Abdi Wahyuda	17	1.12	266	38.1	93.99%
5	Abdi Aris	73	4.30	1758	72.0	74.28%

Berdasarkan Tabel 4.9, terlihat profil aktivitas mahasiswa yang terdeteksi berisiko tinggi. Beberapa mahasiswa menunjukkan pola aktivitas yang sangat rendah, seperti Abdul Adi Syafran Harahap (hanya 1 kali login, nilai 43.7) dan Abdillah Zahwan (7 kali login, nilai 20.0) yang menghasilkan probabilitas penurunan motivasi di atas 94%.

Namun, temuan menarik juga terlihat pada mahasiswa seperti Abdi Aris yang memiliki aktivitas cukup tinggi (73 kali login, durasi 1758 menit, nilai 72.0) tetapi masih terdeteksi memiliki probabilitas turun sebesar 74.28%. Hal ini

mengonfirmasi keunggulan arsitektur model *Multilayer Perceptron* (MLP) yang tidak hanya melihat parameter secara linear; model menganalisis interaksi yang lebih kompleks (non-linear) antara konsistensi login (frekuensi per minggu), total durasi, dan performa nilai untuk mendeteksi anomali yang mengarah pada penurunan motivasi belajar.

4.6 Pembahasan

4.6.1 Interpretasi Kinerja Model MLP

Model MLP yang dikembangkan dalam penelitian ini berhasil mencapai akurasi 92,49%, presisi 93,68%, recall 86,11%, dan F1-Score 89,74%. Seluruh nilai metrik ini melampaui ambang batas kinerja yang ditetapkan sebesar 80%, mengindikasikan bahwa model MLP mampu menjadi alat prediksi yang andal untuk mendeteksi penurunan motivasi belajar mahasiswa pada platform Moodle.

Keberhasilan model MLP dalam mencapai nilai recall yang tinggi (86,11%) sangat penting dalam konteks penelitian ini. Recall yang tinggi berarti model jarang melewatkan mahasiswa yang sesungguhnya mengalami penurunan motivasi. Dalam praktik pendidikan, konsekuensi dari melewatkan mahasiswa bermasalah (*false negative*) jauh lebih serius dibandingkan dengan memberikan perhatian kepada mahasiswa yang sebetulnya tidak bermasalah (*false positive*), karena keterlambatan intervensi dapat berdampak pada penurunan prestasi akademik, penundaan kelulusan, bahkan putus kuliah.

4.6.2 Pengaruh Aktivitas Login Terhadap Motivasi Belajar

Temuan penelitian ini mengonfirmasi hipotesis bahwa aktivitas login

mahasiswa pada platform Moodle berkorelasi signifikan dengan kondisi motivasi belajar mereka. Variabel Frekuensi login terbukti menjadi prediktor terkuat dengan koefisien korelasi −0,80 terhadap probabilitas penurunan motivasi. Hal ini sejalan dengan teori keterlibatan belajar (*learning engagement theory*) yang menyatakan bahwa frekuensi keterlibatan dalam aktivitas pembelajaran daring merupakan indikator utama motivasi intrinsik mahasiswa.

Menariknya, variabel durasi akses (−0,59) memiliki korelasi yang lebih lemah dibandingkan jumlah login dan frekuensi. Hal ini dapat diinterpretasikan bahwa konsistensi keterlibatan (seberapa sering login) lebih berpengaruh terhadap motivasi dibandingkan dengan lamanya waktu yang dihabiskan dalam satu sesi akses. Temuan ini memiliki implikasi penting bagi desain sistem pemantauan keterlibatan mahasiswa.



Gambar 4.3 *Box Plot Jumlah Login terhadap Motivasi Belajar*

Berdasarkan Gambar 4.3, terlihat perbedaan distribusi aktivitas login yang sangat kontras antara kedua kelompok. Mahasiswa dengan motivasi normal (kotak hijau) memiliki nilai tengah (*median*) aktivitas login yang tinggi, yakni sekitar 80 kali, dengan keterlibatan yang sangat konsisten. Sebaliknya, kelompok

mahasiswa yang mengalami penurunan motivasi (kotak merah) memiliki *median* yang jauh lebih rendah di kisaran 40 kali dengan sebaran data yang sangat bervariasi dan fluktuatif. Perbedaan visual yang terpisah jauh ini dengan jelas mengonfirmasi kuatnya korelasi (−0,80) bahwa semakin rendah dan tidak konsistennya jumlah login, semakin besar probabilitas mahasiswa tersebut mengalami penurunan motivasi belajar.

4.6.3 Implikasi Praktis bagi Pengelolaan Pembelajaran Daring

Hasil penelitian ini memiliki beberapa implikasi praktis yang dapat langsung diterapkan dalam pengelolaan pembelajaran daring di institusi pendidikan yang menggunakan Moodle. Pertama, sistem prediksi berbasis MLP yang dikembangkan dapat diintegrasikan ke dalam alur kerja akademik sebagai sistem peringatan dini (*early warning system*) yang secara otomatis mengidentifikasi mahasiswa berisiko.

Kedua, segmentasi risiko ke dalam empat kategori (sangat tinggi, tinggi, sedang, rendah) memungkinkan alokasi sumber daya intervensi yang lebih efisien. Dosen atau konselor akademik dapat memprioritaskan waktu dan perhatian mereka kepada 6,6% mahasiswa dalam segmen risiko sangat tinggi, sementara mahasiswa dalam segmen sedang dapat ditangani melalui notifikasi otomatis atau program tutoring berbasis kelompok.

Ketiga, frekuensi login per minggu dapat dijadikan indikator monitoring mingguan yang mudah dipantau tanpa memerlukan komputasi prediksi penuh. Mahasiswa dengan frekuensi login di bawah 1 kali per minggu selama dua minggu berturut-turut dapat langsung ditandai sebagai kandidat intervensi awal.

4.6.4 Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan yang perlu diakui. Pertama, data yang digunakan hanya mencakup satu tahun akademik dari satu institusi, sehingga generalisabilitas model ke institusi lain atau periode waktu yang berbeda perlu divalidasi lebih lanjut melalui studi replikasi.

Kedua, label motivasi belajar pada sebagian besar data (74,99%) dihasilkan melalui mekanisme auto-labeling heuristik berdasarkan pola aktivitas, bukan melalui pengukuran motivasi yang terstandarisasi seperti skala psikometri (*e.g.*, Academic Motivation Scale). Keterbatasan ini berpotensi menimbulkan bias pada proses pelatihan model.

Ketiga, model yang dikembangkan hanya menggunakan empat variabel aktivitas Moodle. Faktor-faktor lain yang berpotensi memengaruhi motivasi belajar mahasiswa, seperti kondisi ekonomi, beban kerja, dukungan keluarga, dan faktor psikologis individual, tidak dimasukkan dalam model karena keterbatasan ketersediaan data.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah diuraikan pada Bab IV, dapat ditarik beberapa kesimpulan sebagai berikut:

1. Model Multilayer Perceptron (MLP) yang dikembangkan dalam penelitian ini berhasil memprediksi penurunan motivasi belajar mahasiswa pengguna Moodle dengan tingkat akurasi sebesar 92,49%, presisi 93,68%, recall 86,11%, dan F1-Score 89,74% Seluruh nilai metrik evaluasi melampaui ambang batas kinerja yang ditetapkan sebesar 80%, membuktikan bahwa MLP merupakan algoritma yang efektif untuk kasus klasifikasi prediksi motivasi belajar pada data aktivitas LMS.
2. Proses preprocessing data yang diterapkan secara sistematis, mencakup pembersihan data, standarisasi kolom, normalisasi dengan StandardScaler, dan penanganan ketidakseimbangan kelas, terbukti berkontribusi signifikan terhadap kualitas model. Normalisasi StandardScaler khususnya berperan penting dalam menstabilkan proses pelatihan MLP mengingat perbedaan skala yang signifikan antar variabel fitur.
3. Variabel frekuensi login per minggu (korelasi −0,80) merupakan prediktor terkuat penurunan motivasi belajar, diikuti oleh jumlah login (−0,78), nilai rata-rata akademik (−0,71), dan durasi akses (−0,59). Temuan ini mengindikasikan bahwa konsistensi keterlibatan mahasiswa pada platform Moodle, yang tercermin dari frekuensi dan jumlah login, lebih berpengaruh

terhadap motivasi

belajar dibandingkan lamanya waktu yang dihabiskan dalam satu sesi akses.

4. Variabel yang paling mempengaruhi prediksi motivasi belajar mahasiswa adalah frekuensi login, yang dibuktikan dengan nilai korelasi negatif terkuat sebesar -0,80. Hal ini sejalan dengan teori keterlibatan belajar, di mana konsistensi mahasiswa dalam mengakses LMS merupakan indikator utama tingginya motivasi intrinsik. Semakin rutin mahasiswa melakukan aktivitas login, semakin menyusut probabilitas mereka untuk mengalami penurunan motivasi, yang membuktikan bahwa konsistensi akses jauh lebih penting daripada sekadar lamanya waktu yang dihabiskan dalam satu sesi.

5.2 Saran

Berdasarkan hasil penelitian dan keterbatasan yang telah diidentifikasi, beberapa saran dikemukakan untuk pengembangan penelitian selanjutnya serta implementasi praktis di institusi pendidikan:

1. Penelitian lanjutan perlu melibatkan data dari beberapa institusi pendidikan yang berbeda untuk menguji tingkat generalisasi model MLP terhadap variasi karakteristik mahasiswa dan kebijakan akademik.
2. Disarankan memperkaya dataset dengan variabel di luar aktivitas teknis Moodle, seperti skor motivasi dari instrumen psikometri, data demografi, dan faktor dukungan sosial agar hasil prediksi lebih komprehensif.
3. Penelitian selanjutnya dapat mengeksplorasi metode *Deep Learning* berbasis waktu seperti *Long Short-Term Memory* (LSTM) untuk memprediksi pola perubahan aktivitas mahasiswa secara sekuensial dari waktu ke waktu.
4. Sistem prediksi yang dikembangkan sebaiknya diimplementasikan sebagai

modul terintegrasi dalam sistem informasi akademik, dilengkapi dengan prosedur standar operasional (SOP) untuk penanganan mahasiswa berisiko.

5. Institusi disarankan membangun proses pelabelan data motivasi yang terstandarisasi, misalnya melalui survei rutin setiap semester, untuk meningkatkan kualitas pelatihan model dan mengurangi bias dari *auto-labeling* heuristik.

DAFTAR PUSTAKA

Akuntansi, I., Alfamart, K. P., Selebar, D. I. K., & Bengkulu, K. (2024). SISTEM INFORMASI AKUNTANSI BERBASIS MOBILE DALAM PENINGKATAN KINERJA PADA ALFAMART, DI KECAMATAN SELEBAR, KOTA BENGKULU. *JURNAL AKUNTANSI KEUANGAN DAN TEKNOLOGI INFORMASI AKUNTANSI*, *5*(1), 92–110.

Alnasyan, B., Basheri, M., & Alassafi, M. (2024). The power of Deep Learning techniques for predicting student performance in Virtual Learning Environments: A systematic literature review. *Computers and Education: Artificial Intelligence*, *6*(December 2023), 100231. https://doi.org/10.1016/j.caeai.2024.100231

Ardianti, M., Nurhayati, O. D., & Warsito, B. (2024). Model Prediksi Kinerja Siswa Berdasarkan Data Log LMS Menggunakan Ensemble Machine Learning. *JST (Jurnal Sains Dan Teknologi)*, *12*(3), 562–571. https://doi.org/10.23887/jstundiksha.v12i3.59816

Arti, S., & Suherlan, E. (2025). E ISSN : 2809-4069 Evaluasi Kinerja Machine Learning dalam Memprediksi Kemampuan Adaptasi Mahasiswa pada Lingkungan Pembelajaran Daring. *Jurnal Pustaka*, *5*(1), 50–57.

Azis, A. R. (2025). Analisis Komparasi Algoritma Machine Learning dalam Prediksi Performa Akademik Mahasiswa: Literature Review. *Jurnal Ilmu Komputer Dan Informatika*, *4*(2), 143–148. https://doi.org/10.54082/jiki.212

Bela, Awan Anhara, & Rhifwan Aji Bimantoro Adriyanto. (2025). Pengaruh Motivasi Belajar terhadap Peningkatan Prestasi Akademik Siswa Siswi SMA Global Indonesia School. *Jurnal Pengabdian Cendekia*, *1*(2), 159–163. https://doi.org/10.71417/jpc.v1i2.46

Budiman, J. (2021). VOX EDUKASI : Jurnal Ilmiah Ilmu Pendidikan EVALUASI PELAKSANAAN PEMBELAJARAN DARING DI INDONESIA SELAMA MASA PANDEMI COVID-19. *Jurnal Ilmiah Ilmu Pendidikan*, *12*(April), 104–113.

Caspari-Sadeghi, S. (2022). Applying Learning Analytics in Online Environments: Measuring Learners' Engagement Unobtrusively. *Frontiers in Education*, *7*(January), 1–6. https://doi.org/10.3389/feduc.2022.840947

Diva, A. S., Chairunnisa, A. A., & Mufidah, T. H. (2021). Pembelajaran daring pada masa pandemi covid-19 {Online learning during the covid-19 pandemic}. *El Midad: 1st National Conference on Education, System and Technology Information*, *1*(1), 86–100.

Folorunsho, O., Fagbuagun, O. A., Ochidi, I., Faboya, O. O., & Hassan, J. B. (2025). Performance Comparison of Feature Selection Techniques for Stroke Prediction Using Multilayer Perceptron * 1. *Journal of Engineering and*

Technology, *10*(1).

Gulo, S. H., Lubis, A. H., Informatika, T., Teknik, F., & Area, U. M. (2024). Penerapan Multi-Layer Perceptron untuk Mengklasifikasi Penduduk Kurang Mampu. *EXPLORER Journal of Computer Science and Information Technology*, *4*(2), 51–59.

Ika, C., Budhayanti, S., Studi, P., Profesi, P., & Pendidikan, F. (2023). PENGGUNAAN LEARNING MANAGEMENT SYSTEM (LMS) MOODLE PADA PERKULIAHAN PENDIDIKAN MATEMATIKA DI PROGRAM STUDI PENDIDIKAN GURU SEKOLAH DASAR. *Jurnal Pendidikan, Psikologi, Dan Konseling*, *21*(1), 50–62. https://doi.org/10.25170/psikoedukasi.v21i1.4439

Johar, N. A., Kew, S. N., Tasir, Z., & Koh, E. (2023). Learning Analytics on Student Engagement to Enhance Students' Learning Performance: A Systematic Review. *Sustainability (Switzerland)*, *15*(10), 1–25. https://doi.org/10.3390/su15107849

Manajemen, J., Informasi, S., Gilliani, W., Rasywir, E., & Pradana, L. Y. (2024). Perancangan Sistem Informasi Pengadaan Barang Berbasis Web (Studi Kasus : CV . Royal Transindo) Jurnal Manajemen Teknologi dan Sistem Informasi (JMS). *Jurnal Manajemen Teknologi Dan Sistem Informasi*, *4*, 657–666.

Mardinah, D., & Thoriq, M. (2022). Algoritma Multi Layer Perceptron sebagai Prediksi Kelulusan Mahasiswa Universitas Adzkia Tepat Waktu berdasarkan jenis kelamin, Indeks Prestasi Semester, dan Jumlah SKS yang ditempuh. *Jurnal Rekayasa Sistem Komputasi Dan Manajemen*, *1*(1), 26–35. https://ojs.adzkia.ac.id/

Muhammad Imam Syafi'i, Ramdanil Mubarok, Y. (2019). Pendidikan Dasar dan Keguruan. *Pendidikan Dasar Dan Keguruan*, *4*(2), 53–62.

Nugroho, P. A. (2023). KOMPUTA : Jurnal Ilmiah Komputer dan Informatika IMPLEMENTASI JARINGAN SYARAF TIRUAN MULTI-LAYER PERCEPTRON UNTUK PREDIKSI PENYINARAN KOMPUTA : Jurnal Ilmiah Komputer dan Informatika. *Jurnal Ilmiah Komputer Dan Informatika*, *12*(1), 83–90.

Nurhalizah, R. S., & Ardianto, R. (2024). Analisis Supervised dan Unsupervised Learning pada Machine Learning : Systematic Literature Review. *Jurnal Ilmu Komputer Dan Informatika (JIKI)*, *4*(1), 61–72.

Pratama, R., & Eviyanti, A. (2024). Perancangan dan Pembuatan Sistem Informasi Berbasis Website Untuk Sales Marketing. *Indonesian Journal of Applied Technology*, *3*, 1–16.

Putra, F. (2022). MEMBANGUN E-LEARNING MENGGUNAKAN MOODLE SEBAGAI ALAT BANTU PEMBELAJARAN PADA MASA PANDEMI

COVID-19 DI FAKULTAS ILMU KOMPUTER. *Jurnal SIMTIKA*, *5*(1), 35–41.

Regita, N. (2023). *Pengertian dan Manfaat Learning Management System (LMS)*. Artikel. https://suteki.co.id/pengertian-dan-manfaat-learning-management-system-lms

Sari, F., Harahap, W., Mazaly, M. R., Sihotang, S. F., Sari, F., Harahap, W., Mazaly, M. R., & Korelasi, P. (2024). MES : Journal of Mathematics Education and Science MENGANALISIS HUBUNGAN PENGGUNAAN BAHAN AJAR BERBASIS DARING DAN PRESTASI AKADEMIK MAHASISWA Siti Fatimah Sihotang * * Corresponding Author : siti.fatimah.sihotang@gmail.com kreativitas dalam proses pembel. *Journal of Mathematics Education and Science*, *10*(1).

Sujon, K. M., Hassan, R., Choi, K., & Samad, M. A. (2025). Accuracy, precision, recall, f1-score, or MCC? empirical evidence from advanced statistics, ML, and XAI for evaluating business predictive models. *Journal of Big Data*, *12*(1). https://doi.org/10.1186/s40537-025-01313-4

Wulandari, O., Tohir, A., Daring, P., & Pendidikan, K. (2024). PENGGUNAAN LEARNING MANAGEMENT SYSTEM (LMS) DALAM MENINGKATKAN KUALITAS PEMBELAJARAN DARING DI. *Jurnal Review Pendidikan Dan Pengajaran*, *7*, 10490–10496.

Yuda, Y. P., & Kurniawati, I. D. (2024). *Pengembangan e-Learning Berbasis Moodle sebagai Alternatif Media Pembelajaran Digital*. Artikel. https://jurnal.itscience.org/index.php/digitech/article/view/4420/3396

MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PERSYARIKATAN
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UMSU Terakreditasi Unggul Berdasarkan
Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 6622459 Fax. (061) 6625474 - 6631003
umsumedan umsumedan umsumedan umsumedan

KEPUTUSAN DEKAN
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
Nomor : 1084/KEP/II.3.AU/UMSU-09/F/2025

Tentang :
PENGANGKATAN DOSEN PEMBIMBING SKRIPSI
PRODI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

بسم الله الرحمن الرحيم

Dekan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara, setelah:

Menimbang :
1. Bahwa sehubungan dengan pelaksanaan Tugas Akhir Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara;
2. Bahwa untuk memenuhi maksud tersebut perlu diterbitkan surat keputusan Dekan Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara.

Mengingat :
1. Undang-undang Republik Indonesia No. 12 Tahun 2012 tentang Pendidikan Tinggi;
2. Peraturan Pemerintah Nomor 4 Tahun 2014 tentang Penyelenggaraan Pendidikan Tinggi dan Pengelolaan Perguruan Tinggi;
3. Pedoman Perguruan Tinggi Muhammadiyah;
4. Statuta Universitas Muhammadiyah Sumatera Utara
5. Keputusan Rektor No. 1001/KEP/II.3-AU/UMSU/D/2025 tanggal 25 Oktober 2025 tentang Dekan Fakultas Ilmu Komputer dan Teknologi Informasi UMSU Masa Jabatan 2025-2029
6. Keputusan Rektor No. 624/KEP/II.3.AU/UMSU/D/2025 tentang Prodi Fakultas Ilmu Komputer dan Teknologi Informasi UMSU Masa Jabatan 2025-2029

MEMUTUSKAN

Menetapkan :

KESATU : Menetapkan nama-nama dalam lampiran surat keputusan ini sebagai Dosen Pembimbing Prodi Teknologi Informasi Fakultas Ilmu Komputer dan Teknologi Informasi UMSU.

KEDUA : Keputusan ini berlaku sejak tanggal ditetapkan, dan akan ditinjau serta diperbaiki kembali jika terdapat kekeliruan di kemudian hari.

Ditetapkan di : Medan
Pada tanggal : 18 Jumadil Akhir 1447 H
08 Desember 2025 M

Dekan

Dr. Al-Khowarizmi., M.Kom
NIDN : 0127099201

Tembusan:
1. Yth. Wakil Dekan I & III UMSU di Medan,-
2. Ka. Prodi TI dan Sek. Prodi TI,-
3. Pertinggal.

BAN-PT MQA STARS

MAJELIS PENDIDIKAN TINGGI PENELITIAN & PENGEMBANGAN PERSYARIKATAN
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UMSU Terakreditasi Unggul Berdasarkan
Pusat Administrasi: Jalan Mukhtar Basri No. 3 Medan 20238 Telp. (061) 6622400 - 66224567 Fax. (061) 6625474 - 6631003
umsumedan umsumedan umsumedan umsumedan

Lampiran Dosen Pembimbing Prodi Teknologi Informasi
Nomor : 1084/KEP/II.3.AU/UMSU-09/F/2025
Tanggal : 18 Jumadil Akhir 1447 H /08 Desember 2025 M

PENGANGKATAN DOSEN PEMBIMBING SKRIPSI
PRODI TEKNOLOGI INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA

NO	NAMA	NPM	JUDUL	DOSEN
1	Sri Ningrum	2209020038	Prediksi Kedalaman Air Sumur Pada Musim Kemarau Menggunakan Algoritma Elastic Net Regression Di Desa Bandar Pinang	Farid Akbar Siregar S.Kom., M.Kom.
2	Muhammad Hafizh Syah Utama	220920212	"Penerapan Metode Moving Average dan Single Exponential Smoothing (SES) dalam Prediksi Penjualan Produk Frozen Food: Studi Kasus Toko Rezeki Baru"	Dr. Zainal Azis, M.Si
3	Leydia Aprisa	2209020181	Klasifikasi Penyakit Batang Jagung Menggunakan MobileNetV3 Berbasis Citra Lapangan	Farid Akbar Siregar S.Kom., M.Kom.
4	Gusti Andrean Gunawan	2209020275	Implementasi Sistem IoT pada Miniatur Jembatan Cerdas dengan Deteksi Kapal Menggunakan Sensor Ultrasonik dan Servo	Mhd. Basri, S.Si. M.Kom
5	Malika Rievy Sakina Pohan	2209020023	Implementasi Transfer Learning sebagai Metode Ekstraksi Fitur Citra dengan Dukungan Algoritma CatBoost dalam Sistem Deteksi Dini Penyakit Kulit Scabies pada Kucing	Zuli Agustina Gultom, M.Si
6	Febrina Susmita Rani	2209020220	Prediksi Penurunan Motivasi Belajar pada Pengguna Edmodo Menggunakan Multilayer Perceptron (MLP) sebagai Model Pembelajaran	Zuli Agustina Gultom, M.Si
7	M. Chandra Reswara	2209020136	Rancang Bangun Smart Bento Box Berbasis IoT (ESP32, Sensor Gas MQ-135 & DHT22) untuk Prediksi Kelayakan Konsumsi Multi-Makanan Menggunakan Algoritma XGBoost dan CNN	Mahardika Prawira Tanjung, S.Kom.,M.Kom.

Dekan

Dr. Al-Khowarizmi., M.Kom
NIDN: 0127099201

BAN-PT MQA STARS

PREDIKSI PENURUNAN MOTIVASI BELAJAR PADA PENGGUNA MOODLE MENGGUNAKAN MULTILAYER PERCEPTRON (MLP)

ORIGINALITY REPORT

27%	23%	17%	15%
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	Submitted to Universitas Putera Batam Student Paper	1%
2	kc.umn.ac.id Internet Source	1%
3	suteki.co.id Internet Source	1%
4	ojs.unpkediri.ac.id Internet Source	1%
5	repository.upi.edu Internet Source	1%
6	docplayer.info Internet Source	1%
7	ejurnal.seminar-id.com Internet Source	1%
8	journal.arteii.or.id Internet Source	<1%
9	media.neliti.com Internet Source	<1%
10	eprints.iain-surakarta.ac.id Internet Source	<1%
11	repository.unsoed.ac.id Internet Source	<1%
12	www.researchgate.net Internet Source	<1%
13	Submitted to Thesis 2026 Student Paper	<1%
14	Submitted to Universitas Negeri Jakarta Student Paper	<1%
	www.journal.unublitar.ac.id	

15	Internet Source	<1%
16	123dok.com Internet Source	<1%
17	ejournal.sisfokomtek.org Internet Source	<1%
18	edu.pubmedia.id Internet Source	<1%
19	Submitted to Universitas Pamulang Student Paper	<1%
20	Fatimah Zahra, Imran Imran, Fikri Ashari Anas, Juniarti Iryani. "Pengaruh Efektivitas Diskusi Online Berbasis LMS SPADA terhadap Aktivitas Belajar Mahasiswa", Indonesian Journal of Innovation Multidisipliner Research, 2026 Publication	<1%
21	digilib.unila.ac.id Internet Source	<1%
22	repository.uin-suska.ac.id Internet Source	<1%
23	jptam.org Internet Source	<1%
24	Submitted to Universitas Sangga Buana YPKP Student Paper	<1%
25	Submitted to University of Malaya Student Paper	<1%
26	Submitted to Universitas Sumatera Utara Student Paper	<1%
27	www.ajol.info Internet Source	<1%
28	Submitted to Universitas Muslim Indonesia Student Paper	<1%
29	ejurnal.swadharma.ac.id Internet Source	<1%
30	img1.wsimg.com Internet Source	<1%
31	www.liputan6.com Internet Source	<1%

32	Submitted to UPN Veteran Yogyakarta Student Paper	<1%
33	e-journal.hamzanwadi.ac.id Internet Source	<1%
34	Kardoni Gulo, Solihin Solihin, Riska Hayati, Holilah Holilah. "SISTEM PENDATAAN PENJUALAN PADA CV TASYA BUNGSU BERBASIS WEB", Journal of Innovation And Future Technology (IFTECH), 2025 Publication	<1%
35	Robby Pratama, Ade Eviyanti. "Perancangan dan Pembuatan Sistem Informasi Berbasis Website Untuk Sales Marketing", Indonesian Journal of Applied Technology, 2024 Publication	<1%
36	Submitted to Universitas Musamus Merauke Student Paper	<1%
37	jurnal.polban.ac.id Internet Source	<1%
38	Kui Xie, Zilu Jiang, Qiwei Men, Zilong Pan, Jingwen He. "Profiles of students' behavioral engagement and their associations to academic motivation in online learning", Journal of Computing in Higher Education, 2025 Publication	<1%
39	Submitted to Universitas Budi Luhur Student Paper	<1%
40	prosiding.aritekin.or.id Internet Source	<1%
41	repository.umsu.ac.id Internet Source	<1%
42	Bergas Cahyo Nuswantoro, Rolis Liu, Mohammad Ichsan Nurdin, Purwantoro. "SISTEM PENDUKUNG KEPUTUSAN EVALUASI RISIKO PENIPUAN TRANSAKSI KEUANGAN MENGGUNAKAN RANDOM FOREST", Jurnal Mahasiswa Sistem Informasi (JMSI), 2026 Publication	<1%
43	Submitted to Universitas Wijaya Kusuma Surabaya Student Paper	<1%
44	Submitted to Konsorsium PTS Batch 5 Student Paper	<1%
45	etheses.uin-malang.ac.id Internet Source	<1%

46	Submitted to Universitas Muhammadiyah Makassar Student Paper	<1%
47	journal.nurulfikri.ac.id Internet Source	<1%
48	jurnal.ubhinus.ac.id Internet Source	<1%
49	repo.darmajaya.ac.id Internet Source	<1%
50	repository.ar-raniry.ac.id Internet Source	<1%
51	Aulia Puspa, Aviarini Indrati. "Implementasi Algoritma Random Forest Classifier Dalam Klasifikasi Kelayakan Air Minum", RIGGS: Journal of Artificial Intelligence and Digital Business, 2026 Publication	<1%
52	Submitted to Universitas Negeri Yogyakarta Student Paper	<1%
53	Luthfia Nurma Hapsari, Ilham Fannani, Yenny Rahmawati, Ahmad Muhariya. "Explainable Machine Learning untuk Prediksi Risiko Penyakit Jantung Menggunakan Random Forest dan Analisis SHAP", remik, 2026 Publication	<1%
54	journal.perbanas.id Internet Source	<1%
55	repository.uinsu.ac.id Internet Source	<1%
56	Arjan Saputra Harahap, Asnil Aidah Ritonga. "Pendidikan Berbasis Merdeka Belajar dalam Perspektif Al-Quran", Jurnal Pendidikan Tambusai, 2026 Publication	<1%
57	jurnal.peneliti.net Internet Source	<1%
58	sitasi.upnjatim.ac.id Internet Source	<1%
59	journal.universitaspahlawan.ac.id Internet Source	<1%
60	komputasi.fmipa.unila.ac.id Internet Source	<1%
61	repo.unand.ac.id	

	Internet Source	<1%
62	repository.its.ac.id Internet Source	<1%
63	Submitted to Management & Science University Student Paper	<1%
64	eprints.umg.ac.id Internet Source	<1%
65	Submitted to Universitas Islam Riau Student Paper	<1%
66	dspace.uii.ac.id Internet Source	<1%
67	journalcenter.org Internet Source	<1%
68	Submitted to Forum Perpustakaan Perguruan Tinggi Indonesia Jawa Timur Student Paper	<1%
69	Submitted to IAIN Pontianak Student Paper	<1%
70	Mochammad Dayke Xavier Lumankun, Ghofar Taufik. "Algoritma Naïve Bayes untuk Analisis Sentimen Pengguna Game Honor of King Berdasarkan Ulasan di Google Play Store", RIGGS: Journal of Artificial Intelligence and Digital Business, 2026 Publication	<1%
71	journalversa.com Internet Source	<1%
72	zephyrnet.com Internet Source	<1%
73	Submitted to Erciyes Ãniversitesi Student Paper	<1%
74	Submitted to Sriwijaya University Student Paper	<1%
75	Submitted to UM Surabaya Student Paper	<1%
76	Submitted to Universitas Indonesia Student Paper	<1%
	jurnal.fkip.untad.ac.id	

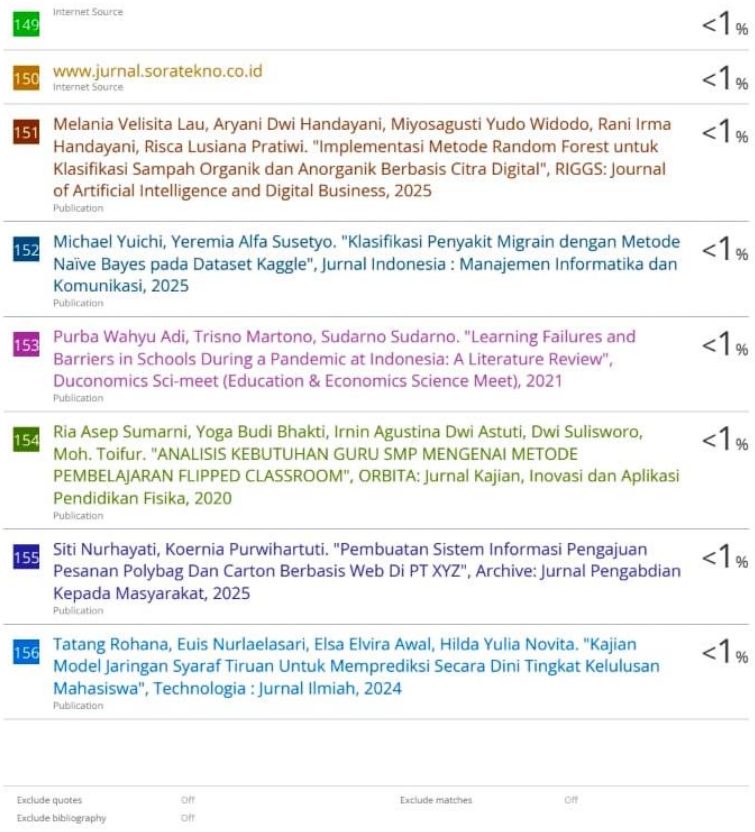
77	Internet Source	<1%
78	jutif.if.unsoed.ac.id Internet Source	<1%
79	ocw-mirror.telkomuniversity.ac.id Internet Source	<1%
80	qdoc.tips Internet Source	<1%
81	Muhammad Jamil. "**Pengaruh Kebiasaan Belajar dan Motivasi Belajar Terhadap Prestasi Belajar Akuntansi Siswa Kelas XII di SMK Negeri Taman Fajar Tahun Ajaran 2024/2025**", Jurnal Pendidikan Penggerak, 2025 Publication	<1%
82	Supiyandi, Adinda Fita Hidayah, Luthfie Budie, Rafif Rasendriya, Nurhalijah Berutu, Fakhita Fahraini. "PENDETEKSIAN DAN PENGHITUNGAN KENDARAAN MENGGUNAKAN ALGORITMA COUNTER DALAM KONTEKS PENGOLAHAN CITRA", PROSISKO: Jurnal Pengembangan Riset dan Observasi Sistem Komputer, 2024 Publication	<1%
83	Submitted to Universitas Katolik Widya Mandala Surabaya Student Paper	<1%
84	id.123dok.com Internet Source	<1%
85	journalinstal.cattleyadf.org Internet Source	<1%
86	jurnal.umt.ac.id Internet Source	<1%
87	repository.um-palembang.ac.id Internet Source	<1%
88	Submitted to Badan PPSDM Kesehatan Kementerian Kesehatan Student Paper	<1%
89	Everd Elseos Martin Utubira, Junikles Pangeti. "REFORMULASI MANAJEMEN PENDIDIKAN ERA DIGITALISASI: KAJIAN IMPLEMENTASI LEARNING MANAGEMENT SYSTEM DI LINGKUNGAN PENDIDIKAN", PEDAGOGIKA: Jurnal Pedagogik dan Dinamika Pendidikan, 2025 Publication	<1%
90	Submitted to Institut Bisnis dan Teknologi Indonesia (INSTIKI) Student Paper	<1%
	Submitted to Politeknik Penerbangan Surabaya	

91	Student Paper	<1%
92	Submitted to Sekolah Teknik Elektro & Informatika Student Paper	<1%
93	Shefhira Amanda Oktavia, Antonius Ian Bayu Setiawan. "Penerimaan diri pada mahasiswa dengan anhedonia", PSYCOMEDIA : Jurnal Psikologi, 2024 Publication	<1%
94	Submitted to Universitas Dian Nuswantoro Student Paper	<1%
95	Submitted to Universitas Malikussaleh Student Paper	<1%
96	digilibadmin.unismuh.ac.id Internet Source	<1%
97	journal.eng.unila.ac.id Internet Source	<1%
98	repository.unisda.ac.id Internet Source	<1%
99	www.neliti.com Internet Source	<1%
100	www.ojs.unkriswina.ac.id Internet Source	<1%
101	Akbar Supia Dirja, Lana Aulia Salsabila, M. Akhdan Putra Hermawan, Cika Jelita, Hanif Zaidan Sinaga. "Analisis Sentimen MBG Di Media Sosial X Menggunakan Support Vector Machine Dan Naive Bayes", Indonesian Journal of Multidisciplinary on Social and Technology, 2026 Publication	<1%
102	Galih Hermawan. "Klasifikasi Pengemudi Terganggu Berdasarkan Citra Menggunakan ResNet-50", Jurnal Informatika Komputer, Bisnis dan Manajemen, 2024 Publication	<1%
103	Submitted to Universitas Airlangga Student Paper	<1%
104	ejurnal.stmik-budidarma.ac.id Internet Source	<1%
105	journals.upi-yai.ac.id Internet Source	<1%

106	repository.unhas.ac.id Internet Source	<1%
107	Ade Toti Febrian, Purwadi Purwadi, Adam Prayogo Kuncoro. "Comparative Analysis of Data-Level and Cost-Sensitive Learning in IndoBERT-Based Sentiment Analysis of Ruangguru App Reviews", Jambura Journal of Electrical and Electronics Engineering, 2026 Publication	<1%
108	Miraj Fuadi, M. Azhar Mustafid, Rosyid Ridho, Endang Purnama Dewi, Eusabius Paul Pega. "Model Deteksi Gulma dan Tanaman Jagung Berbasis YOLOv5n untuk Sistem Pertanian Presisi", Jurnal Agricultural Biosystem Engineering, 2026 Publication	<1%
109	Muhamad Zaril Akbar, Dadang Priyanto, Ria Rismayati. "Prediksi Tingkat Realisasi Pupuk Bersubsidi Menggunakan Support Vector Machine (SVM)", RIGGS: Journal of Artificial Intelligence and Digital Business, 2026 Publication	<1%
110	Submitted to UIN Raden Intan Lampung Student Paper	<1%
111	Ulfani Rohima Zalti, Dinda Rose Darmakusuma, Muhammad Ridwansyah, Edi Ismanto. "Analisis dan Prediksi Kelayakan Air Minum Menggunakan Algoritma Random Forest", JURNAL FASILKOM, 2025 Publication	<1%
112	Firamawati Hia, Ronita Olive Angelie, Lotar Mateus Sinaga. "Implementasi Deep Learning untuk Prediksi Penggunaan Resource CPU dan RAM pada Server Debian Linux", RIGGS: Journal of Artificial Intelligence and Digital Business, 2026 Publication	<1%
113	M Tohir Karjono. "PENGGUNAAN TABEL MT KUANTUM UNTUK MENINGKATKAN HASIL BELAJAR SISWA PADA MATERI STRUKTUR ATOM DAN SISTEM PERIODIK DI KELAS X MIPA 5 SMAN 1 TANJUNGPINANG", Jurnal Zarah, 2018 Publication	<1%
114	ejournal.omahtabing.com Internet Source	<1%
115	eprints.mdp.ac.id Internet Source	<1%
116	id.scribd.com Internet Source	<1%
117	jurnal.polibatam.ac.id Internet Source	<1%
	jurnal.umb.ac.id	

118	Internet Source	<1%
119	publikasi.mercubuana.ac.id Internet Source	<1%
120	repo.itera.ac.id Internet Source	<1%
121	repository.ub.ac.id Internet Source	<1%
122	repository.ubharajaya.ac.id Internet Source	<1%
123	repository.uinbanten.ac.id Internet Source	<1%
124	repository.usd.ac.id Internet Source	<1%
125	sipora.polije.ac.id Internet Source	<1%
126	www.scribd.com Internet Source	<1%
127	Aris Tjahyanto, Faisal Johan Atletiko. "Peningkatan Kinerja Pengklasifikasi Objek Bawah Laut dengan Deep Learning", MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer, 2022 Publication	<1%
128	Harliana Harliana, Tito Prabowo, Ady Alzhava Nuary. "Perbandingan Logistic Regression dan Random Forest untuk Prediksi Respon Pelanggan Asuransi", Jurnal Informatika Komputer, Bisnis dan Manajemen, 2026 Publication	<1%
129	Submitted to IAIN Tulungagung Student Paper	<1%
130	Lely Kurniawati, Dadang Priyanto, Neny Sulistia Ningsih, Moch Syahrir, Ria Rismayati. "Comparison of Decision Tree-Based Methods in Lung Disease Detection", Jurnal Bumigora Information Technology (BITe), 2025 Publication	<1%
131	Tiara Adinda Puspita, Adellia Febriyanti, Ardhana Aryaldi Rahmadani, Dicky Apdillah. "Sistem Pengenalan Ekspresi Wajah Menggunakan Deep Learning dengan Arsitektur MobileNetV2", Jurnal Pengabdian Masyarakat dan Riset Pendidikan, 2026 Publication	<1%

132	Submitted to Universitas 17 Agustus 1945 Semarang Student Paper	<1%
133	doku.pub Internet Source	<1%
134	e-journal.ivet.ac.id Internet Source	<1%
135	ejournal.indo-intellectual.id Internet Source	<1%
136	eprints.undip.ac.id Internet Source	<1%
137	fr.scribd.com Internet Source	<1%
138	journal.institercom-edu.org Internet Source	<1%
139	journal.ipm2kpe.or.id Internet Source	<1%
140	journal.ummat.ac.id Internet Source	<1%
141	jtiik.ub.ac.id Internet Source	<1%
142	jurnal.itg.ac.id Internet Source	<1%
143	jurnal.stkippgritulungagung.ac.id Internet Source	<1%
144	lppm.stkippacitan.ac.id Internet Source	<1%
145	repository.ummat.ac.id Internet Source	<1%
146	repository.unika.ac.id Internet Source	<1%
147	repository.unj.ac.id Internet Source	<1%
148	www.dosenpendidikan.co.id Internet Source	<1%
	www.freecodecamp.org	



149	Internet Source	<1%
150	www.jurnal.soratekno.co.id Internet Source	<1%
151	Melania Velisita Lau, Aryani Dwi Handayani, Miyosagusti Yudo Widodo, Rani Irma Handayani, Risca Lusiana Pratiwi. "Implementasi Metode Random Forest untuk Klasifikasi Sampah Organik dan Anorganik Berbasis Citra Digital", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Publication	<1%
152	Michael Yuichi, Yeremia Alfa Susetyo. "Klasifikasi Penyakit Migrain dengan Metode Naïve Bayes pada Dataset Kaggle", Jurnal Indonesia : Manajemen Informatika dan Komunikasi, 2025 Publication	<1%
153	Purba Wahyu Adi, Trisno Martono, Sudarno Sudarno. "Learning Failures and Barriers in Schools During a Pandemic at Indonesia: A Literature Review", Duconomics Sci-meet (Education & Economics Science Meet), 2021 Publication	<1%
154	Ria Asep Sumarni, Yoga Budi Bhakti, Irnin Agustina Dwi Astuti, Dwi Sulisworo, Moh. Toifur. "ANALISIS KEBUTUHAN GURU SMP MENGENAI METODE PEMBELAJARAN FLIPPED CLASSROOM", ORBITA: Jurnal Kajian, Inovasi dan Aplikasi Pendidikan Fisika, 2020 Publication	<1%
155	Siti Nurhayati, Koernia Purwihartuti. "Pembuatan Sistem Informasi Pengajuan Pesanan Polybag Dan Carton Berbasis Web Di PT XYZ", Archive: Jurnal Pengabdian Kepada Masyarakat, 2025 Publication	<1%
156	Tatang Rohana, Euis Nurlaelasari, Elsa Elvira Awal, Hilda Yulia Novita. "Kajian Model Jaringan Syaraf Tiruan Untuk Memprediksi Secara Dini Tingkat Kelulusan Mahasiswa", Technologia : Jurnal Ilmiah, 2024 Publication	<1%

Exclude quotes	Off	Exclude matches	Off
Exclude bibliography	Off		