

**PENERAPAN ALGORITMA *K-NEAREST NEIGHBOR* DALAM
ANALISIS PEMINJAMAN BARANG PADA DIVISI
INVENTARIS TVRI MAKASSAR**

SKRIPSI

Diajukan Sebagai Salah Satu Syarat untuk Mendapat Gelar Sarjana Komputer
(S.Kom) Program Studi Informatika



**PROGRAM STUDI INFORMATIKA
FAKULTAS TEKNIK UNIVERSITAS MUHAMMADIYAH
MAKASSAR 2025**

**PENERAPAN ALGORITMA *K-NEAREST NEIGHBOR* DALAM
ANALISIS PEMINJAMAN BARANG PADA DIVISI
INVENTARIS TVRI MAKASSAR**

SKRIPSI

Diajukan Sebagai Salah Satu Syarat untuk Mendapat Gelar Sarjana Komputer
(S.Kom) Program Studi Informatika

Disusun Dan Diajukan Oleh :

RISAL

105841104921

PROGRAM STUDI INFORMATIKA

FAKULTAS TEKNIK

UNIVERSITAS MUHAMMADIYAH MAKASSAR 2025

MAJELIS PENDIDIKAN TINGGI PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH MAKASSAR
FAKULTAS TEKNIK



PENGESAHAN

Skripsi atas nama Risal dengan nomor induk Mahasiswa 105841104921, dinyatakan diterima dan disahkan oleh Panitia Ujian Tugas Akhir/Skripsi sesuai dengan Surat Keputusan Dekan Fakultas Teknik Universitas Muhammadiyah Makassar Nomor : 0004/SK-Y/55202/091004/2025, sebagai salah satu syarat guna memperoleh gelar Sarjana Komputer pada Program Studi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar pada hari Sabtu, 30 Agustus 2025.

Panitia Ujian :

1. Pengawas Umum

a. Rektor Universitas Muhammadiyah Makassar

Dr. Ir. H. Abd. Rakhim Nanda, ST.,MT.,IPU

b. Dekan Fakultas Teknik Universitas Hasanuddin

Prof. Dr. Eng. Muhammad Isran Ramli, S.T., MT., ASEAN., Eng

Makassar,

16 Rabi'ul Awal 1447 H

9 September 2025 M

2. Pengaji

a. Ketua

: Dr.Ir. Zahir Zainuddin, M.Sc.

b. Sekertaris

EMIL AGUSALUM HABI TALIB, S.Pd.,M.Eng.

3. Anggota

1. DESI ANGGREANI, S.kom., MT.

2. LUKMAN, S.Kom, M.T.

3. Runal Rezkiawan B, S.Kom., M.T.

Pembimbing I

Chyquitha danuputri S.kom., M.Kom.

Pembimbing II

Darmati S.Kom., MT.

Dekan



I. Muh. Syafaat S. Kuba, S.T., M.T.

NBM 5795 288

**MAJELIS PENDIDIKAN TINGGI PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH MAKASSAR**

FAKULTAS TEKNIK



HALAMAN PENGESAHAN

Tugas Akhir ini diajukan untuk memenuhi syarat ujian guna memperoleh gelar Sarjana Komputer (S.Kom) Program Studi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar.

Judul Skripsi: **PENERAPAN ALGORITMA K-NEAREST NEIGHBOR DALAM ANALISIS PEMINJAMAN BARANG PADA DIVISI INVENTARIS TVRI MAKASSAR**

Nama : Risal
Stambuk : 105 841104921

Makassar, 9 September 2025

Telah Diperiksa dan Disetujui
Oleh Dosen Pembimbing;

Pembimbing I

Chyquitha danuputri S.kom., M.Kom.

Pembimbing II

Darmijat S.Kom., MT.

Mengetahui,

Ketua Prodi Informatika



MOTTO DAN PERSEMBAHAN

MOTTO

“Dari setiap keraguan dan hinaan, lahir motivasi terbesar untuk membuktikan kalau kita bisa dan melangkah jauh ke depan.”

PERSEMBAHAN

Tiada skripsi yang sempurna tanpa doa, rahmat, dan pertolongan dari Allah SWT. Dengan segala kerendahan hati, karya sederhana ini saya persembahkan kepada Allah SWT, Zat yang Maha Pengasih dan Maha Penyayang, atas segala nikmat, kesehatan, dan kesempatan yang diberikan hingga saya dapat menyelesaikan skripsi ini dan saya persembahkan kepada kedua orang tua tercinta yang selalu menjadi sumber kekuatan, teladan, dan penyemangat dalam setiap langkah hidup saya. Doa, kasih sayang, dan pengorbanan kalian menjadi alasan terbesar saya untuk tidak pernah menyerah. Persembahan ini juga saya tunjukan kepada dosen pembimbing serta seluruh pengajar yang telah membimbing dengan penuh kesabaran, sahabat dan rekan seperjuangan yang selalu memberi serta semangat yang tak ternilai harganya dalam melewati setiap proses hingga terselesaiannya skripsi ini. serta saya persembahkan untuk almamater tercinta, Universitas Muhammadiyah Makassar, tempat saya menimba ilmu dan membentuk diri menjadi pribadi yang lebih baik.

ABSTRAK

RISAL, penerapan algoritma *k-nearest neighbor* dalam analisis peminjaman barang pada divisi inventaris tvri Makassar (Di Bimbing Oleh Chyquitha Danuputri, S.Kom., M.Kom, dan Ibu Darniati S.Kom., MT)

divisi inventaris tvri makassar menghadapi tantangan dalam analisis data peminjaman barang akibat proses pencatatan yang masih manual dan ketiadaan sistem analitik prediktif, sehingga menyulitkan perencanaan kebutuhan aset secara proaktif. penelitian ini bertujuan untuk menerapkan algoritma *k-nearest neighbor* (knn) guna menganalisis pola peminjaman barang, memprediksi item yang kemungkinan besar akan dipinjam dalam periode tiga bulan ke depan, serta mengukur tingkat akurasi model yang dihasilkan. metode penelitian ini menggunakan alur kerja *machine learning* yang sistematis, mencakup pra-pemrosesan data, rekayasa fitur, penanganan kelas tidak seimbang menggunakan *synthetic minority over-sampling technique* (smote), dan optimasi *hyperparameter* melalui *gridsearchcv* untuk menemukan konfigurasi model terbaik ($k=3$, metrik=*euclidean*, bobot=*distance*). kinerja model dievaluasi menggunakan metrik akurasi, presisi, *recall*, *f1-score*, dan *confusion matrix*. hasil penelitian menunjukkan model knn berhasil mencapai akurasi keseluruhan sebesar 80,18%, secara signifikan melampaui model dasar (18,5%). model menunjukkan kinerja sangat andal ($f1\text{-score} > 0.95$) untuk aset dengan volume data historis yang besar seperti 'camera' dan 'battery', namun performanya bervariasi pada kategori aset dengan data terbatas. simulasi prediksi berhasil mengidentifikasi tren permintaan bulanan dan harian yang dapat menjadi dasar pengambilan keputusan berbasis data untuk manajemen inventaris yang lebih efisien dan efektif.

kata kunci: analisis peminjaman, data *mining*, *inventaris*, *k-nearest neighbor*, *machine learning*, prediksi

ABSTRACT

RISAL, penerapan algoritma k-nearest neighbour analisis dalam peminjaman barang pada divisi inventaris tvri makassar (Di Bimbing Oleh Chyquitha Danuputri, S.Kom., M.Kom, dan Ibu Darniati S.Kom., MT)

The TVRI Makassar Inventory Division faces challenges in analyzing item borrowing data due to the manual recording process and the lack of a predictive analytics system, making proactive asset requirements planning difficult. This study aims to apply the K-Nearest Neighbor (KNN) algorithm to analyze item borrowing patterns, predict items most likely to be borrowed in the next three months, and measure the accuracy of the resulting model. This research method uses a systematic machine learning workflow, including data preprocessing, feature engineering, handling imbalanced classes using the Synthetic Minority Oversampling Technique (SMOTE), and hyperparameter optimization using GridSearchCV to find the best model configuration ($k=3$, metric=euclidean, weight=distance). Model performance was evaluated using accuracy, precision, recall, F1-Score, and Confusion Matrix metrics. The results showed that the KNN model achieved an overall accuracy of 80.18%, significantly exceeding the baseline model (18.5%). The model demonstrated highly reliable performance ($F1\text{-Score} > 0.95$) for assets with large historical data volumes, such as 'Camera' and 'Battery', but its performance varied for asset categories with limited data. Predictive simulations successfully identified monthly and daily demand trends that can inform data-driven decision-making for more efficient and effective inventory management.

Keywords: *Lending Analysis, Data Mining, Inventory, K-Nearest Neighbor, Machine Learning, Prediction*

KATA PENGANTAR

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Puji dan syukur penulis ucapan terhadap kehadiran Tuhan yang maha Esa, yang telah melimpahkan rahmat hidayah dan karunia-Nya pada penulis, sehingga penulis dapat menyelesaikan penulisan skripsi ini yang berjudul “**Penerapan Algoritma K-Nearest Neighbor dalam Analisis Peminjaman Barang pada Divisi Inventaris TVRI Makassar**” Shalawat dan salam kepada Rasulullah Shalallahu ‘Alaihi Wasalam yang senantiasa menjadi sumber inspirasi dan teladan terbaik untuk umat manusia

Pada kesempatan ini dengan segala kerendahan hati, penulis ingin mengucapkan terima kasih sebesar besarnya kepada semua pihak yang telah banyak membantu dalam penulisan skripsi ini, teruntuk kepada

1. Ucapan terima kasih yang setulus-tulusnya saya sampaikan kepada kedua orang tua penulis, yang dengan penuh kasih sayang, kesabaran serta doa yang tiada henti selalu mendampingi setiap langkah penulis. Terima kasih atas dukungan moral, dan materi yang telah Ibu dan Ayah berikan sejak awal hingga akhir proses penulisan skripsi ini. Segala jerih payah, pengorbanan, dan cinta yang kalian curahkan menjadi sumber kekuatan terbesar bagi Penulis untuk terus berjuang dan menyelesaikan pendidikan ini.
2. Bapak Dr. Ir. Abd. Rakhim Nanda, S.T., M.T., IPU, selaku Rektor Universitas Muhammadiyah Makassar.
3. Bapak Muhammad Syafa’at S Kuba, S.T., M.T, selaku Wakil Dekan Fakultas Teknik Universitas Muhammadiyah Makassar.
4. Ibu Rizki Yusliana Bakti, S.T., M.T selaku Ketua Program Studi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar.
5. Ibu Chyquitha danuputri S.kom., M.Kom, selaku Dosen Pembimbing I, yang dengan penuh ketulusan, kesabaran, dan dedikasi telah memberikan arahan, bimbingan, serta saran-saran yang sangat berharga dalam setiap tahap penyusunan skripsi ini. Atas segala ilmu, waktu, dan dukungan yang diberikan, penulis menyampaikan rasa terima kasih yang sebesar-besarnya.

6. Ibu Darniati S.Kom., MT, selaku Dosen Pembimbing II, yang dengan penuh kesabaran dan ketelitian telah memberikan arahan, bimbingan, serta saran-saran yang sangat berharga dalam proses penulisan skripsi ini. Atas segala perhatian, waktu, dan ilmu yang telah diberikan, penulis menyampaikan rasa terima kasih yang sebesar-besarnya.
7. Ibu Desi Anggreani, S.Kom., M.T., yang dengan penuh kesabaran dan ketulusan, memberikan ilmu, serta senantiasa membantu penulis dalam proses penyusunan skripsi ini. penulis mengucapkan rasa terima kasih yang sebesar-besarnya.
8. Bapak dan Ibu dosen pengajar di Program Studi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar, yang telah memberikan ilmu serta dorongannya dalam penulisan skripsi ini.
9. Pegawai Tata Usaha Fakultas Teknik Universitas Muhammadiyah Makassar yang telah membantu dalam pengurusan berkas dan administrasi sehingga proses penyusunan skripsi ini berjalan dengan baik.
10. Bapak/Ibu pegawai Dinas TVRI Provinsi Sulawesi Selatan, yang dengan penuh keramahan dan keterbukaan telah memberikan bantuan, izin, serta berbagai informasi yang sangat berharga bagi kelancaran pengumpulan data dan proses penelitian ini. atas segala dukungan dan kerja samanya, penulis menyampaikan rasa terima kasih yang sedalam-dalamnya.
11. Terima kasih kepada Mahasiswi PGSD dengan NIM 105401116922, yang telah setia menemani, mendukung, dan memberikan semangat sejak awal hingga akhir proses ini. Kehadirannya menjadi sumber kekuatan yang berarti bagi penulis dalam menyelesaikan skripsi ini.
12. Terima kasih Untuk para sahabat dan rekan seperjuangan penulis, Syahril Akbar, Muhammad Adil Syaputra, Ulil Amri, Gempar, Nur Alam, Makmur dan Sony, terima kasih telah menjadi teman berbagi dalam suka dan duka selama proses penggerjaan skripsi ini. Setiap diskusi, canda tawa, dan semangat yang kalian berikan merupakan hal yang tak ternilai harganya dan membuat perjalanan ini terasa lebih ringan.

13. Teman-teman khususnya angkatan 2021 Program Studi Informatika Fakultas Teknik Universitas Muhammadiyah Makassar.
14. Kepada semua pihak yang sudah membantu, Penulis mengucapkan banyak terima kasih yang sebesar-besarnya.

Penulis menyadari bahwa dalam penulisan skripsi ini masih terdapat kekurangan untuk itu penulis mengharapkan kritik dan saran. Akhir kata, penulis berharap semoga skripsi ini dapat bermanfaat bagi semua pihak demi pengembangan dan kemajuan akademik.



Makassar, 28 Agustus 2025

Penulis,

Risal

DAFTAR ISI

MOTTO DAN PEMBAHASAN.....	i
ABSTRAK	ii
KATA PENGANTAR.....	iv
DAFTAR ISI	vii
DAFTAR GAMBAR	ix
DAFTAR TABLE.....	ix
DAFTAR ISTILAH	x
BAB I PENDAHULUAN	1
A. Latar Belakang	1
B. Rumusan Masalah	2
C. Tujuan Penelitian	2
D. Manfaat Penelitian.....	3
E. Ruang Lingkup Penelitian	3
F. Sistematika Penulisan	4
BAB II TINJAUAN PUSTAKA	5
A. Landasan Teori.....	5
B. Penelitian Terkait	11
C. Kerangka Berpikir	14
BAB III METODOLOGI PENELITIAN.....	15
A. Tempat dan waktu Penelitian	15
B. Alat dan bahan	16
C. Perancangan Sistem.....	17
D. Teknik Pengujian Sistem	22
E. Teknik Analisis Data	25
BAB IV HASIL DAN PEMBAHASAN.....	28
A. Pengumpulan Data	28
B. Detail Pra-pemrosesan Data	29
C. Penerapan Metode <i>K-Nearest Neighbor</i> (KNN)	31
D. Analisis Mendalam Kinerja per Kelas	35

E.	Perhitungan Manual Akurasi.....	38
F.	Perhitungan Manual <i>K-Nearest Neighbor</i> (KNN)	42
G.	Analisis Visualisasi Hasil Prediksi	44
H.	Proyeksi Permintaan Model vs. Realitas Peminjaman	52
I.	Implikasi Manajerial dan Keterbatasan.....	54
BAB V	PENUTUP.....	55
A.	Kesimpulan	55
B.	Saran	55
DAFTAR	PUSTAKA	57
LAMPIRAN	61



DAFTAR GAMBAR

Gambar 1. Diagram Kerangka Berpikir.....	14
Gambar 2. Lokasi Penelitian TVRI Stasiun.....	15
Gambar 3. Perancangan Sistem.....	17
Gambar 4. Penerapan <i>K-Nearest Neighbor</i> (KNN).....	21
Gambar 5. <i>Confusion Matrix Model KNN</i>	37
Gambar 6 Grafik <i>time series</i> 3 bulan ke depan.....	46
Gambar 7 Detail Prediksi Peminjaman bulan Mei.....	48
Gambar 8 Detail Prediksi Peminjaman bulan Juni.....	49
Gambar 9 Detail Prediksi Peminjaman bulan Juli.....	51



DAFTAR TABLE

Tabel 1. Perbedaan Penelitian Terdahulu dan Penelitian Saat ini.....	12
Tabel 2. Sampel Data Mentah Peminjaman Barang.....	28
Tabel 3. Contoh Penyederhanaan Nama Alat.....	29
Tabel 4. Parameter yang digunakan.....	31
Tabel 5. Parameter terbaik yang digunakan.....	32
Tabel 6. Pengujian Parameter.....	33
Tabel 8. Hasil Pengujian Sistem.....	35
Tabel 9. laporan klasifikasi Matrix.....	36
Tabel 10. Perhitungan TP per kelas.....	39
Tabel 11. data Latih 5 Baris Pertama.....	42
Tabel 12. output prediksi barang 3 bulan ke depan.....	44
Tabel 13. peminjaman barang pada dunia nyata.....	52
Tabel 14. perbandingan hasil prediksi.....	53
Tabel 15. Keterangan Kepercayaan.....	54

DAFTAR ISTILAH

<i>Akurasi (Accuracy)</i>	Metrik evaluasi yang mengukur proporsi total prediksi yang benar (baik positif maupun negatif) dari keseluruhan data uji.
<i>Algoritma (Algorithm)</i>	Serangkaian instruksi atau prosedur langkah-demi-langkah yang terdefinisi dengan baik untuk menyelesaikan masalah atau melakukan komputasi.
<i>Baseline Model (Model Dasar)</i>	Model sederhana yang digunakan sebagai titik referensi untuk membandingkan kinerja model yang lebih kompleks. Dalam penelitian ini, model dasar memprediksi kelas mayoritas secara konsisten.
<i>Confusion Matrix</i>	Sebuah tabel yang digunakan untuk memvisualisasikan kinerja algoritma klasifikasi dengan merangkum jumlah prediksi benar dan salah untuk setiap kelas.
<i>Cross-Validation (Validasi Silang)</i>	Teknik evaluasi model di mana data latih dibagi menjadi beberapa bagian (lipatan atau folds) untuk melatih dan menguji model secara berulang, guna menghasilkan estimasi kinerja yang lebih stabil dan andal.
<i>Data Mining</i>	Proses penggalian pola, anomali, atau pengetahuan yang berharga dan tersembunyi dari kumpulan data besar menggunakan teknik analisis statistik dan <i>machine learning</i> .
<i>Encoding</i>	Proses mengubah data kategorial (non-numerik) menjadi format numerik agar dapat diproses oleh algoritma <i>machine learning</i> .

<i>F1-Score</i>	Rata-rata harmonik dari <i>Precision</i> dan <i>Recall</i> , yang memberikan ukuran kinerja tunggal yang menyeimbangkan kedua metrik tersebut, sangat berguna pada kasus data tidak seimbang.
<i>Feature Engineering (Rekayasa Fitur)</i>	Proses membuat fitur-fitur baru dari data yang ada untuk meningkatkan kemampuan prediktif model.
<i>GridSearchCV</i>	Sebuah teknik untuk melakukan optimasi <i>hyperparameter</i> secara sistematis dengan menguji semua kombinasi nilai parameter yang telah ditentukan untuk menemukan konfigurasi terbaik.
<i>Hyperparameter (Hiperparameter)</i>	Parameter konfigurasi eksternal dari sebuah model yang nilainya diatur sebelum proses pelatihan dimulai, seperti nilai 'k' pada KNN.
<i>Inventaris (Inventory)</i>	Daftar lengkap barang atau aset yang dimiliki oleh sebuah organisasi, yang dalam konteks ini merujuk pada peralatan operasional di TVRI Makassar.
<i>K-Nearest Neighbor (KNN)</i>	Salah satu algoritma <i>supervised learning</i> yang bekerja dengan mengklasifikasikan data baru berdasarkan mayoritas kelas dari 'k' tetangga terdekatnya dalam data latih.
<i>Klasifikasi (Classification)</i>	Sebuah tugas dalam <i>machine learning</i> untuk memetakan data <i>input</i> ke dalam kelas atau kategori yang telah ditentukan sebelumnya.
<i>Overfitting</i>	Sebuah kondisi di mana model <i>machine learning</i> memiliki kinerja yang sangat baik pada data latih tetapi buruk pada data baru

	(data uji), karena model terlalu "menghafal" data latih termasuk <i>noise</i> .
<i>Pra-pemrosesan Data (Data Preprocessing)</i>	Serangkaian langkah yang dilakukan untuk membersihkan, mentransformasi, dan menyiapkan data mentah agar sesuai dan berkualitas untuk diolah oleh model <i>machine learning</i> .
<i>Presisi (Precision)</i>	Metrik yang mengukur proporsi prediksi positif yang benar-benar positif. Metrik ini menjawab pertanyaan: "Dari semua yang diprediksi sebagai kelas X, berapa persen yang benar?"
<i>Recall (Sensitivity)</i>	Metrik yang mengukur kemampuan model untuk menemukan semua sampel positif yang sebenarnya. Metrik ini menjawab pertanyaan: "Dari semua kejadian kelas X yang sebenarnya, berapa persen yang berhasil diprediksi oleh model?"
<i>SMOTE (Synthetic Minority Over-sampling Technique)</i>	Sebuah teknik <i>oversampling</i> yang digunakan untuk mengatasi masalah ketidakseimbangan kelas dengan cara membuat sampel sintetis baru untuk kelas minoritas.
<i>Spesifisitas (Specificity)</i>	Metrik yang mengukur proporsi prediksi negatif yang benar-benar negatif, atau kemampuan model dalam mengidentifikasi data negatif dengan benar.
<i>Supervised Learning</i>	Salah satu paradigma <i>machine learning</i> di mana model belajar dari data yang telah diberi label (input dan output yang benar) untuk membuat prediksi.
	Daftar lampiran

DAFTAR LAMPIRAN

Lampiran 1 data mentah.....	61
Lampiran 2. Code program.....	66
Lampiran 3 Hasil prediksi.....	78
Lampiran 4. Permohonan penelitian.....	82
Lampiran 5. Surat Rekomendasi Penelitian dari LP3M.....	83
Lampiran 6. Surat Izin Penelitian dari PTSP.....	84
Lampiran 7. Surat Izin Penelitian dari Dinas TVRI Sulawesi Selatan.....	85
Lampiran 8. Hasil Turniting.....	86
Lampiran 9. Hasil turniting bab 1-5.....	87



BAB I

PENDAHULUAN

A. Latar Belakang

Pengelolaan aset yang efisien merupakan aspek krusial dalam menunjang operasional lembaga penyiaran seperti TVRI, di mana ketersediaan dan pemanfaatan inventaris secara optimal sangat menentukan kelancaran kegiatan siaran (Rizkia Malik et al., 2023). Saat ini divisi Inventaris TVRI Makassar masih menghadapi tantangan dalam optimalisasi analisis data peminjaman barang. Proses pencatatan yang cenderung manual dan kurangnya sistem analitik prediktif menyulitkan perencanaan kebutuhan aset secara proaktif, terutama untuk periode mendatang. Keterbatasan ini berpotensi mengganggu efisiensi operasional, alokasi anggaran, dan pada akhirnya dapat mempengaruhi kesiapan Divisi Inventaris TVRI Makassar dalam mendukung kelancaran kegiatan penyiaran.

Permasalahan terkait kurangnya sistem analisis data yang terstruktur dalam pengelolaan inventaris bukan hanya dialami TVRI Makassar, melainkan isu umum di berbagai organisasi. Ketidakakuratan data dan kesulitan pelacakan aset kerap menimbulkan inefisiensi, sehingga mendorong pengembangan solusi berbasis teknologi untuk meningkatkan akurasi dan aksesibilitas data (Pranoto & Sediyono, 2021). Lebih lanjut ketidaksesuaian antara data stok dengan kondisi fisik, serta minimnya pemantauan pergerakan aset, dapat mengakibatkan penumpukan barang yang tidak perlu, peningkatan biaya operasional, atau sebaliknya, kekurangan barang kritis pada saat dibutuhkan e(Hijrah & Maulidar, 2021). Konsekuensinya, perencanaan perawatan, penambahan stok, dan alokasi sumber daya menjadi kurang tepat sasaran (Heldi Hastriyandi, 2023).

Dalam upaya mengatasi keterbatasan analisis manual dan menggali wawasan prediktif dari data historis peminjaman, teknik *data Mining* menggunakan algoritma *K-Nearest Neighbor* (KNN) menawarkan solusi yang menjanjikan. KNN merupakan metode klasifikasi non-para metrik berbasis jarak (kedekatan) yang telah terbukti efektif dalam berbagai kasus, termasuk mengidentifikasi pola dan mendukung pengambilan keputusan. Relevansi KNN terlihat pada studi analisis pola peminjaman buku di perpustakaan (Hasanah et al., 2022), prediksi item terlaris

untuk manajemen stok yang lebih baik (Rahma et al., 2024), serta klasifikasi data transaksi pinjaman pada sektor keuangan (Ardhana et al., 2024). Potensi KNN dalam analisis pola dan pengelolaan stok secara umum juga diperkuat oleh penelitian lain yang menunjukkan kemampuannya dalam menangani data dengan karakteristik serupa (Syahril Dwi Prasetyo et al., 2023) Keunggulan KNN terletak pada kesederhanaan konsepnya, kemampuannya menangani data Multi-kelas, dan efektivitasnya pada data set yang tidak terlalu besar namun memiliki pola kedekatan yang jelas, yang sesuai dengan data peminjaman inventaris.

Berdasarkan tantangan yang ada di Divisi Inventaris TVRI Makassar dan potensi signifikan dari algoritma KNN, penelitian ini bertujuan untuk menerapkan algoritma KNN guna menganalisis pola peminjaman barang inventaris dan secara spesifik memprediksi barang-barang yang memiliki kemungkinan besar akan dipinjam dalam periode tiga bulan ke depan. Penelitian ini juga akan mengukur kinerja akurasi model KNN dalam konteks pengelolaan aset di TVRI Makassar. Diharapkan, hasil penelitian ini dapat memberikan kontribusi nyata dalam menciptakan sistem pengelolaan inventaris yang lebih efektif, efisien, dan berbasis data, sehingga mendukung pengambilan keputusan yang lebih informatif.

B. Rumusan Masalah

Berdasarkan latar belakang masalah yang telah diuraikan, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana penerapan algoritma *K-Nearest Neighbor* (KNN) dalam menganalisis pola peminjaman barang pada Divisi Inventaris TVRI Makassar?
2. Bagaimana tingkat akurasi dari algoritma *K-Nearest Neighbor* (KNN) terhadap data peminjaman barang pada Divisi Inventaris TVRI Makassar?

C. Tujuan Penelitian

Sesuai dengan rumusan masalah, tujuan dari penelitian ini adalah

1. Menerapkan algoritma *K-Nearest Neighbor* (KNN) untuk menganalisis pola peminjaman barang dan menghasilkan daftar barang yang kemungkinan besar akan dipinjam dalam periode tiga bulan ke depan pada Divisi Inventaris TVRI Makassar.

2. Mengukur dan mengetahui tingkat akurasi algoritma *K-Nearest Neighbor* (KNN) dalam menganalisis data peminjaman barang pada Divisi *Inventaris* TVRI Makassar.

D. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut

1. Bagi Divisi *Inventaris* TVRI Makassar

Memberikan informasi analitis mengenai pola peminjaman barang dan identifikasi barang yang paling sering dipinjam. Menjadi bahan pertimbangan dalam pengambilan keputusan terkait manajemen inventaris, seperti prioritas perawatan, perencanaan penambahan stok, atau pengadaan barang baru. Membantu meningkatkan efisiensi pengelolaan aset di Divisi Inventaris. Mengetahui kemungkinan barang apa yang akan di pinjam 3 bulan berikutnya

2. Bagi Penulis

Memenuhi salah satu syarat kelulusan untuk memperoleh gelar Sarjana Komputer pada Program Studi Informatika, Fakultas Teknik, Universitas Muhammadiyah Makassar. Meningkatkan pemahaman dan kemampuan penulis dalam menerapkan algoritma data Mining untuk menyelesaikan masalah nyata.

3. Bagi Akademisi

Menambah pengetahuan dan wawasan dalam bidang data Mining, khususnya penerapan algoritma KNN pada kasus analisis peminjaman *inventaris* di lembaga penyiaran. Menjadi referensi atau dasar bagi penelitian selanjutnya yang berkaitan dengan analisis data *inventaris* atau penerapan algoritma *machine learning* lainnya.

E. Ruang Lingkup Penelitian

Berdasarkan perumusan masalah di atas, dapat di susun beberapa batasan peneliti, yaitu

1. Data histori yang di gunakan bersumber dari histori peminjaman barang di Divisi *Inventaris* TVRI Makassar.

2. Metode Analisis hanya menggunakan Algoritma klasifikasi *K-Nearest Neighbor* (KNN) tidak mencakup perbandingan kinerja dengan algoritma data Mining lainnya.
3. Fokus penelitian ini adalah mengklasifikasikan jenis barang yang berpeluang dipinjam dalam tiga bulan ke depan menggunakan algoritma *K-Nearest Neighbor* (KNN), dengan mempertimbangkan hari-hari yang secara historis memiliki tingkat peminjaman di atas 15%. Penelitian ini tidak berfokus pada pengembangan sistem informasi inventaris secara keseluruhan.
4. Evaluasi Kinerja akan dilakukan berfokus pada tingkat akurasi (*Accuracy*) model KNN.

F. Sistematika Penulisan

Sistematika penulisan penelitian ini terbagi menjadi beberapa BAB, masing-masing sebagai berikut:

BAB 1 PENDAHULUAN

Bab ini berisi Latar Belakang Masalah, Rumusan Masalah, Tujuan Penelitian, Manfaat Penelitian, Ruang Lingkup Penelitian, dan Sistematika Penulisan.

BAB 2 TINJAUAN PUSTAKA

Bab ini menguraikan landasan teori yang relevan dengan penelitian, meliputi konsep dasar manajemen inventaris, data Mining, algoritma *K-Nearest Neighbor* (KNN), Evaluasi Kinerja Model Klasifikasi KNN , penelitian terkait, dan kerangka berpikir yang berfungsi sebagai panduan sistematis.

BAB 3 METODOLOGI PENELITIAN

Bab ini menjelaskan rancangan penelitian yang digunakan, meliputi Tempat dan Waktu Penelitian, Alat dan Bahan, Perancangan Sistem, Teknik Pengujian Sistem, Serta Teknik Analisis Data

BAB 4 HASIL DAN PEMBAHASAN

Bagian ini menyajikan temuan penelitian beserta analisisnya dalam memprediksi menggunakan metode *K-Nearest Neighbor* (KNN).

BAB 5 PENUTUP DAN SARAN

Bagian ini menyajikan kesimpulan dari hasil penelitian serta saran untuk penelitian selanjutnya.

BAB II

TINJAUAN PUSTAKA

A. Landasan Teori

1. Pengelolaan Aset (*Inventaris*)

Pengelolaan aset merupakan aspek fundamental dalam operasional berbagai organisasi, termasuk lembaga penyiaran seperti TVRI. Pengelolaan aset dapat diartikan sebagai suatu proses sistematis yang mencakup perencanaan, perolehan, pencatatan, penggunaan, pemeliharaan, hingga penghapusan aset guna mencapai tujuan organisasi secara efektif dan efisien. Lebih lanjut, (luki karunia & malik ibrahim politeknik stia lan jakarta, 2021) merinci bahwa pengelolaan aset melibatkan serangkaian kegiatan kompleks mulai dari perencanaan hingga pengendalian, di mana aset yang mencakup proses pembukuan, inventarisasi, dan pelaporan menjadi salah satu komponen krusialnya. Dalam konteks penelitian ini, fokus utama adalah pada pengelolaan aset inventaris, khususnya barang-barang atau peralatan yang dipinjamkan untuk mendukung kegiatan operasional, di mana proses inventarisasi yang meliputi pendataan, pencatatan, dan pelaporan hasil pendataan barang menjadi sangat sentral

Pengelolaan inventaris yang baik, terutama dengan pendekatan berbasis data, bertujuan untuk memastikan ketersediaan barang saat dibutuhkan, meminimalkan biaya penyimpanan dan kerusakan, serta mengoptimalkan aset. Pencatatan yang akurat dan analisis data transaksi inventaris, seperti peminjaman barang, menjadi kunci untuk mencapai tujuan tersebut, karena kegagalan dalam mengelola inventaris secara optimal dapat menyebabkan berbagai masalah seperti kelebihan stok (*overstocking*) yang berbiaya tinggi atau kekurangan stok (*understocking*) yang mengganggu ketersediaan (Farooq et al., 2024). Oleh karena itu, pemanfaatan analisis data untuk memahami pola penggunaan menjadi sangat penting dalam mendukung pengambilan keputusan yang lebih tepat sasaran terkait manajemen inventaris.

Secara khusus, dalam pengelolaan aset inventaris yang memiliki siklus peminjaman dan pengembalian reguler, pemahaman mendalam terhadap pola

penggunaan atau peminjaman menjadi landasan esensial. Ketersediaan data inventaris yang akurat dan mudah diakses, idealnya melalui sistem informasi yang terstruktur seperti yang diusulkan oleh (Christian & Voutama, 2024), untuk mengatasi kendala sistem manual, menjadi prasyarat penting sebelum analisis pola yang lebih mendalam dapat dilakukan secara efektif. Analisis terhadap data historis peminjaman

2. *Data Mining*

Data Mining adalah proses penemuan pengetahuan baru yang bernalih dari kumpulan data besar dengan menggali pola tersembunyi (Jollyta & Ramdhan, 2020), yang bertujuan untuk mentransformasi data mentah menjadi wawasan guna mendukung pengambilan keputusan strategis dan efisiensi operasional (Yang et al., 2020). Berbagai penelitian telah menunjukkan bagaimana analisis *data mining* dapat mengantikan proses manual yang memakan waktu dan rentan kesalahan, sehingga menghasilkan perkiraan atau identifikasi pola yang lebih cepat dan akurat, seperti dalam prediksi peningkatan omzet penjualan menggunakan regresi linier berganda (Siswo Adiguno & Yohanni Syahra & Milfa Yetri, 2022).

Data mining mencakup beragam teknik, termasuk klasifikasi untuk memetakan data ke kelas yang ditentukan, *klasterisasi* untuk mengelompokkan data serupa, dan analisis aturan asosiasi untuk menemukan hubungan antar item (Jollyta & Ramdhan, 2020), dan (Butsianto & Mayangwulan, 2020) menerapkan *K-Means Clustering* untuk mengelompokkan data penjualan mobil guna mengidentifikasi tingkat kelarisan produk. Demikian pula algoritma Apriori telah digunakan untuk menentukan pola ketersediaan stok barang berdasarkan permintaan konsumen, menghasilkan rekomendasi yang mendukung manajemen persediaan (Juniar & Daniawan, 2024).

Pemilihan metode *data mining* yang tepat adalah langkah krusial, bergantung pada tujuan analisis dan karakteristik data. Keberhasilan ekstraksi wawasan sangat ditentukan oleh kesesuaian metode dengan tujuan penelitian serta kualitas data set, di mana kualitas ini sangat dipengaruhi oleh efektivitas tahap pengolahan data (*data preprocessing*)(Çetin & Yıldız, 2022). Dengan

tujuan penelitian untuk memetakan data peminjaman ke kelas-kelas yang ditentukan berdasarkan data historis yang telah diproses, teknik klasifikasi menjadi pendekatan yang paling sesuai (Papakyriakou & Barbounakis, 2022). Oleh karena itu didahului oleh pengolahan data yang cermat, penelitian ini mengadopsi teknik klasifikasi untuk mengidentifikasi pola dan mengklasifikasikan barang berdasarkan frekuensi peminjaman, guna mendukung prediksi kebutuhan aset di TVRI Makassar.

3. Algoritma *K-Nearest Neighbor* (KNN)

Algoritma *K-Nearest Neighbor* (KNN) merupakan salah satu metode *supervised learning* yang fundamental dan sering diterapkan untuk tugas klasifikasi, dikenal karena kesederhanaan konseptualnya dan pendekatan yang intuitif. Prinsip kerjanya adalah mengklasifikasikan sebuah instan data baru berdasarkan kelas mayoritas dari k tetangga terdekatnya yang ada dalam dataset latih yang telah tersimpan. Kedekatan atau kemiripan antar contoh ini diukur menggunakan metrik jarak tertentu dalam ruang fitur. Sebagai algoritma *non-parametrik*, KNN tidak membuat asumsi eksplisit mengenai distribusi data yang mendasarinya, dan tergolong sebagai *instance-based learner* atau *lazy learner* karena tidak ada fase pelatihan model yang eksplisit; komputasi utama, yaitu pencarian tetangga dan penentuan kelas, baru dilakukan pada saat prediksi data baru dibutuhkan. Lebih lanjut, penerapan efektif algoritma ini melibatkan pertimbangan parameter kunci, terutama penentuan nilai k yang optimal. Nilai k merepresentasikan jumlah tetangga terdekat yang akan dilibatkan dalam proses pengambilan keputusan klasifikasi, dan pemilihannya sangat memengaruhi kinerja serta kemampuan generalisasi model. Nilai k yang tidak tepat dapat membuat model terlalu sensitif terhadap noise atau sebaliknya, terlalu menyederhanakan batas keputusan antar kelas (Zhang, 2022).

Implementasi KNN dalam menentukan klasifikasi sebuah contoh baru melibatkan beberapa langkah fundamental. Pertama, dilakukan perhitungan jarak antara contoh baru tersebut dengan semua contoh dalam data latih untuk mengukur tingkat kemiripan. Setelah itu, dilakukan identifikasi k contoh

terdekat berdasarkan hasil perhitungan jarak tersebut. Akhirnya, kelas prediksi untuk contoh baru ditentukan melalui mekanisme proses *voting* mayoritas dari kelas-kelas yang dimiliki oleh k tetangga terdekatnya. Dalam proses ini, pemilihan metrik jarak yang sesuai dengan karakteristik data menjadi aspek yang sangat penting, berdampingan dengan penentuan nilai k . Metrik jarak umum seperti *Euclidean*, *Manhattan*, dan *Minkowski* seringkali dipertimbangkan, di mana pemilihan metrik yang tepat dapat secara signifikan memengaruhi performa algoritma, terutama dalam kaitannya dengan sifat dan skala dimensi data yang dianalisis (Halder et al., 2024) Salah satu metrik yang paling banyak digunakan dalam KNN adalah jarak *Euclidean*, yang dirumuskan sebagai berikut

$$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (1)$$

Keterangan:

- a. $d(p, q)$: jarak antara dua titik data p dan q ,
- b. n : adalah jumlah fitur,
- c. p_i dan q_i : adalah nilai atribut ke i dari masing-masing data

sedangkan rumus *Manhattan* yang kadangkalah juga digunakan sebagai berikut

$$d(p, q) = \sum_{i=1}^n |p_i - q_i| \quad (2)$$

- a. p merupakan vektor fitur data uji,
- b. q merupakan vektor fitur data latih,
- c. n adalah jumlah dimensi atau fitur.

Efektivitas KNN telah ditunjukkan dalam berbagai studi, termasuk dalam analisis pola, prediksi tren, hingga pengelolaan (Tembusai et al., 2021). Dalam konteks peminjaman, KNN juga telah digunakan untuk identifikasi pola peminjaman buku (Hasanah et al., 2022), prediksi penjualan produk terlaris

(Dewi et al., 2022), prediksi kelayakan pinjaman (Fadillah Hermawan & Yamasari, 2022), dan berbagai analisis transaksi lainnya (Ismunandar et al., 2024), (Yenila et al., 2023), dan (Mardiyyah et al., 2024). penelitian ini akan menerapkan teknik *over-sampling SMOTE* (*Synthetic Minority Over-sampling Technique*) untuk menyeimbangkan distribusi data. Pendekatan ini terbukti efektif di mana penelitian oleh (Dwi Astuti & Nova Lenti, 2021)menunjukkan bahwa penggunaan *SMOTE* mampu meningkatkan akurasi.

4. Evaluasi Kinerja Model Klasifikasi KNN

Setelah algoritma *K-Nearest Neighbor* (KNN) menghasilkan prediksi, langkah penting selanjutnya adalah mengevaluasi kinerja model secara menyeluruh untuk mengukur kemampuannya dalam menggeneralisasi data baru. Evaluasi ini juga berguna untuk membandingkan konfigurasi KNN (seperti variasi nilai k atau metrik jarak) maupun membandingkannya dengan algoritma lain. Umumnya, evaluasi dilakukan dengan membagi data menjadi data latih dan data uji. Data latih membentuk model, sementara data uji menilai akurasi prediksi. Tanpa validasi silang, hasil evaluasi bisa bias atau terlalu optimistik, sebagaimana dijelaskan oleh (Aggarwal et al., 2021).

Dasar dari berbagai metrik evaluasi klasifikasi adalah *Confusion Matrix*, yaitu sebuah tabel yang menampilkan hasil klasifikasi model berdasarkan empat kategori:

- a. *True Positives* (TP) jumlah prediksi positif yang benar,
- b. *True Negatives* (TN) jumlah prediksi negatif yang benar,
- c. *False Positives* (FP) jumlah prediksi positif yang salah,
- d. *False Negatives* (FN) jumlah prediksi negatif yang salah.

Berdasarkan *confusion matrix*, beberapa metrik turunan dapat dihitung untuk mengukur performa model secara lebih mendalam. Menurut (Salih & Abdulazeez, 2021), metrik-metrik utama tersebut mencakup

- a. Akurasi (*Accuracy*) mengukur proporsi klasifikasi yang benar dari seluruh prediksi

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

- b. Presisi (*Precision*) menilai seberapa besar bagian dari prediksi positif yang benar

$$\text{Precision} = \frac{TP}{TP+FP} \quad (4)$$

- c. *Recall (Sensitivity / True Positive Rate)* mengukur kemampuan model dalam menemukan semua kasus positif aktual

$$\text{Recall} = \frac{TP}{TP+FN} \quad (5)$$

- d. *F1-Score* merupakan rata-rata harmonik dari presisi dan *recall*, berguna saat distribusi kelas tidak seimbang

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (6)$$

- e. *Spesifisitas (Specificity / True Negative Rate)* menilai seberapa baik model mengidentifikasi data negatif

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (7)$$

Selain itu dia juga menyebutkan bahwa metrik tambahan seperti *Error Rate*, *False Positive Rate (FPR)*, *AUC (Area Under Curve)*, *G-Mean*, dan *Log Loss*, yang dapat digunakan tergantung pada konteks dan kebutuhan klasifikasi. Pemilihan metrik evaluasi yang tepat sangat penting dan bergantung pada tujuan spesifik dari studi, serta konsekuensi dari berbagai jenis kesalahan klasifikasi. Untuk meningkatkan keandalan evaluasi, pendekatan seperti *k-Fold Cross Validation* sering digunakan untuk menghindari overfitting dan menghasilkan estimasi performa yang lebih stabil (Malik Namus Akbar, 2024).

Untuk mengotomatiskan pencarian *hiperparameter* optimal seperti nilai k , sering digunakan teknik Optimasi *Hiperparameter* dengan *Grid Search*. Metode yang diimplementasikan melalui *GridSearchCV*, secara sistematis menguji berbagai kombinasi *hiperparameter* yang telah ditentukan. *GridSearchCV* menggunakan *k-Fold Cross Validation* untuk mengevaluasi setiap kombinasi dan secara otomatis memilih konfigurasi yang menghasilkan performa model terbaik. Pendekatan ini memastikan proses penentuan *hiperparameter* menjadi lebih efisien dan objektif (Artanti et al., n.d.)

5. Simulasi Perhitungan Manual untuk Validasi Konseptual

Untuk memberikan pemahaman yang mendalam dan transparan mengenai mekanisme kerja inti dari algoritma KNN, sebuah contoh simulasi perhitungan manual akan disajikan. Langkah ini bertujuan untuk memvalidasi pemahaman konseptual terhadap proses prediksi, bukan untuk menguji keseluruhan dataset. Pendekatan ini sejalan dengan praktik dalam literatur akademis di mana contoh perhitungan manual disajikan untuk tujuan ilustratif, sebagaimana ditunjukkan oleh (Imron & Kusumah, 2020), yang juga menyajikan contoh perhitungan jarak *Euclidean* dalam penelitiannya.

B. Penelitian Terkait

Beberapa penelitian sebelumnya yang terkait meliputi

1. Penelitian oleh (Hasanah et al., 2022) penelitian ini fokus pada penerapan KNN untuk mengidentifikasi pola peminjaman buku di perpustakaan, baik berdasarkan minat maupun faktor lain. Meskipun objeknya adalah buku, konsep identifikasi item yang sering dipinjam atau memiliki pola tertentu berdasarkan data historis sangat relevan dengan tujuan penelitian ini terhadap inventaris TVRI Makassar.
2. Penelitian oleh (Dewi et al., 2022) Studi ini menunjukkan keberhasilan implementasi KNN untuk memprediksi penjualan produk terlaris dari data transaksi usaha dagang dan prediksi penjualan obat. Fokus pada identifikasi item populer dan dukungan untuk perencanaan stok sangat

sejalan dengan analisis peminjaman barang inventaris yang bertujuan untuk mengetahui barang mana yang paling sering dibutuhkan.

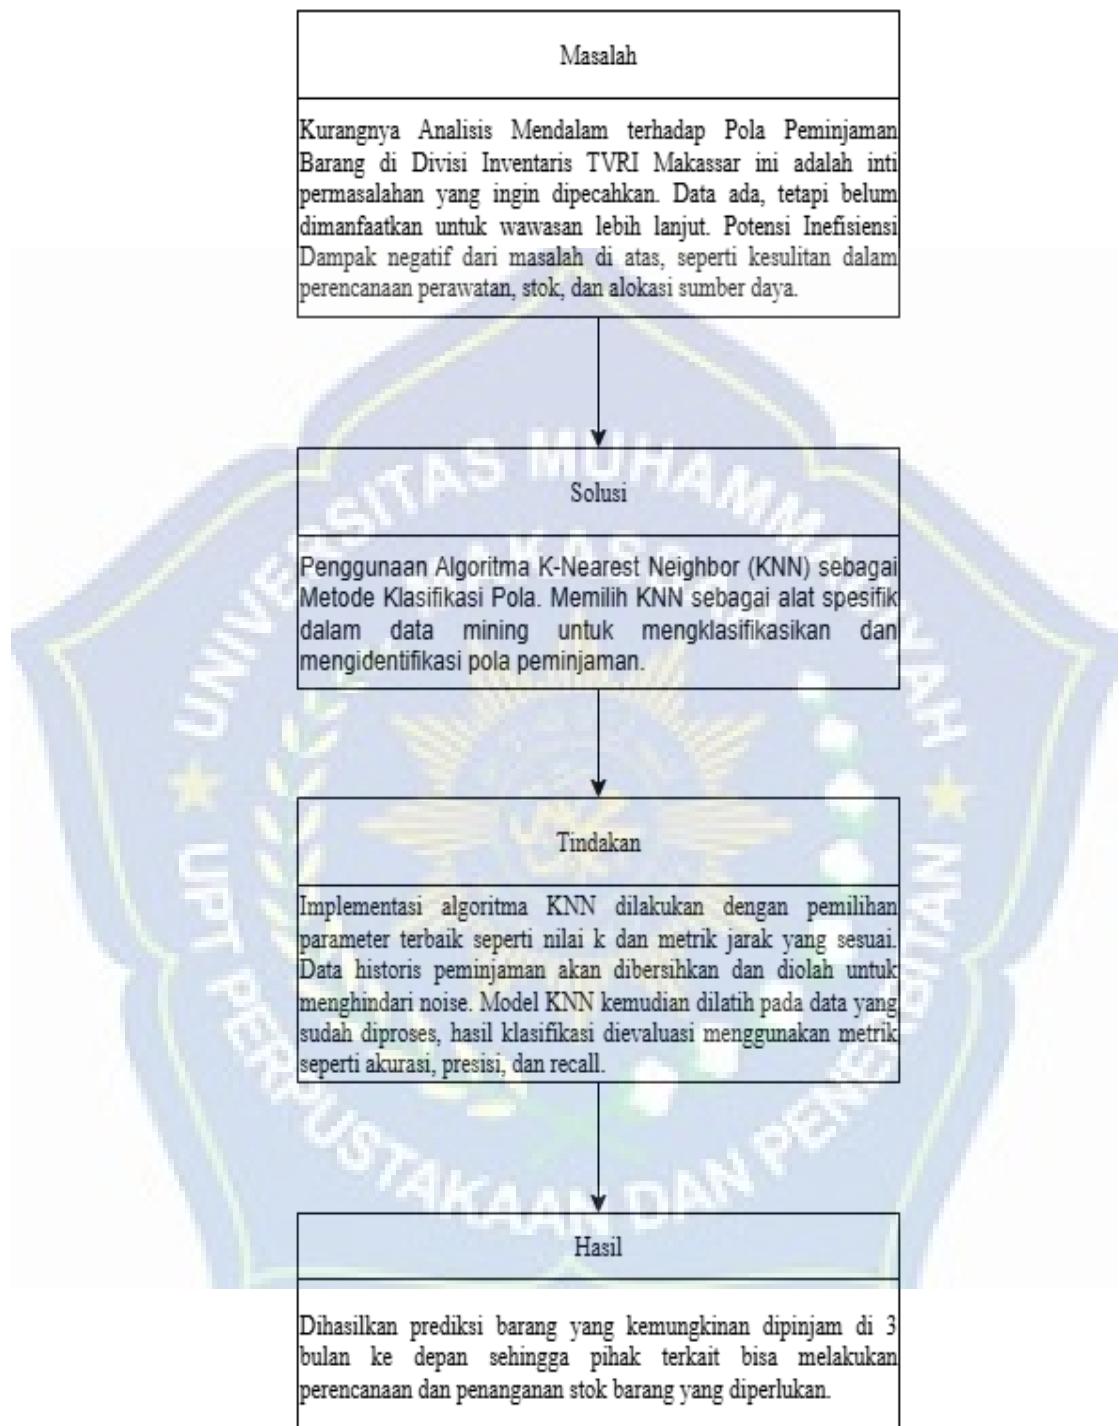
3. Penelitian oleh (Tembusai et al., 2021) Mengindikasikan potensi umum KNN dalam menganalisis pola, memprediksi tren, hingga mendukung pengelolaan stok, memberikan dasar bahwa KNN adalah metode yang layak dipertimbangkan untuk masalah yang serupa dengan yang dihadapi Divisi Inventaris TVRI Makassar.
4. Penelitian oleh (Fadillah Hermawan & Yamasari, 2022) Studi ini secara spesifik mengimplementasikan algoritma KNN untuk menganalisis data transaksi pinjaman dalam konteks sektor finansial, dengan tujuan untuk memprediksi kelayakan pemberian pinjaman. Penelitian ini menunjukkan bahwa KNN dapat memproses data transaksi historis pinjaman dan mengklasifikasikannya untuk tujuan prediktif.
5. Penelitian oleh (Ardhana et al., 2024) Beragam Studi dalam Konteks menerapkan algoritma KNN untuk tugas klasifikasi berdasarkan data transaksi di sektor finansial (misalnya, prediksi gagal pinjam, klasifikasi kredit nasabah, atau penentuan *kolektabilitas*). Studi-studi ini menegaskan kemampuan KNN dalam menganalisis pola historis dari data transaksi dan menggunakan untuk membuat klasifikasi yang mendukung pengambilan keputusan manajerial.

Tabel 1. Perbedaan Penelitian Terdahulu dan Penelitian Saat ini

No	Penelitian Terdahulu	Penelitian Saat Ini
1.	(Hasanah et al., 2022) Menerapkan algoritma <i>K-Nearest Neighbor</i> (KNN) untuk mengidentifikasi pola peminjaman buku di lingkungan perpustakaan berdasarkan minat atau faktor lainnya dari data historis. Fokusnya adalah item buku dan perilaku peminjam perpustakaan.	Objek & Domain Berbeda: Menerapkan algoritma <i>K-Nearest Neighbor</i> (KNN) untuk menganalisis pola peminjaman barang inventaris berupa alat dan perangkat operasional pada Divisi Inventaris lembaga penyiaran publik (TVRI Makassar), bukan buku di perpustakaan. Fokus pada penggunaan aset internal untuk mendukung kegiatan operasional.

No	Penelitian Terdahulu	Penelitian Saat Ini
2.	(Dewi et al., 2022) Menggunakan KNN untuk memprediksi atau mengidentifikasi item populer (produk terlaris/obat) berdasarkan data transaksi penjualan. Tujuannya mendukung perencanaan stok barang komersial.	Konteks & Jenis Transaksi Berbeda: Meskipun tujuannya juga mendukung pengelolaan inventaris, penelitian ini menganalisis data transaksi peminjaman internal aset (bukan penjualan). Fokusnya adalah pada utilitas aset milik organisasi untuk operasional internal, bukan produk yang dijual ke konsumen.
3.	(Tembusai et al., 2021) Merupakan studi yang mengindikasikan potensi umum algoritma KNN dalam menganalisis pola data, melakukan prediksi tren, dan mendukung proses pengelolaan stok secara lebih luas atau konseptual.	Aplikasi Spesifik & Studi Kasus Empiris: Melakukan implementasi dan evaluasi empiris algoritma KNN pada data set spesifik dari Divisi Inventaris TVRI Makassar untuk kasus analisis peminjaman aset nyata, bukan hanya studi potensi umum.
4.	(Fadillah Hermawan & Yamasari, 2022) Mengaplikasikan KNN untuk menganalisis data transaksi pinjaman di sektor finansial dengan tujuan memprediksi kelayakan pemberian pinjaman kepada nasabah berdasarkan histori transaksi mereka.	Jenis Aset & Tujuan Analisis Berbeda: Menganalisis data transaksi peminjaman aset fisik (barang inventaris), bukan pinjaman finansial. Tujuannya adalah untuk memahami pola penggunaan aset dan mengidentifikasi barang yang sering dipinjam, bukan untuk menilai kelayakan pinjaman kepada pihak eksternal.
5.	(Ardhana et al., 2024) Beragam studi yang menerapkan KNN untuk tugas klasifikasi berdasarkan data transaksi di sektor finansial (misalnya, prediksi gagal pinjam, klasifikasi kredit nasabah), menegaskan kemampuan KNN dalam analisis data transaksi untuk keputusan manajerial dan mungkin membahas optimasi parameter.	Domain Non-Finansial & Fokus pada Efisiensi Operasional: Menerapkan KNN pada domain inventaris aset operasional lembaga penyiaran (non-finansial). Tujuan utamanya adalah memberikan wawasan untuk efisiensi pengelolaan aset internal dan perencanaan kebutuhan, bukan klasifikasi risiko kredit atau status finansial pihak eksternal. Akan mengevaluasi kinerja KNN dalam konteks spesifik ini.

C. Kerangka Berpikir



Gambar 1. Diagram Kerangka Berpikir

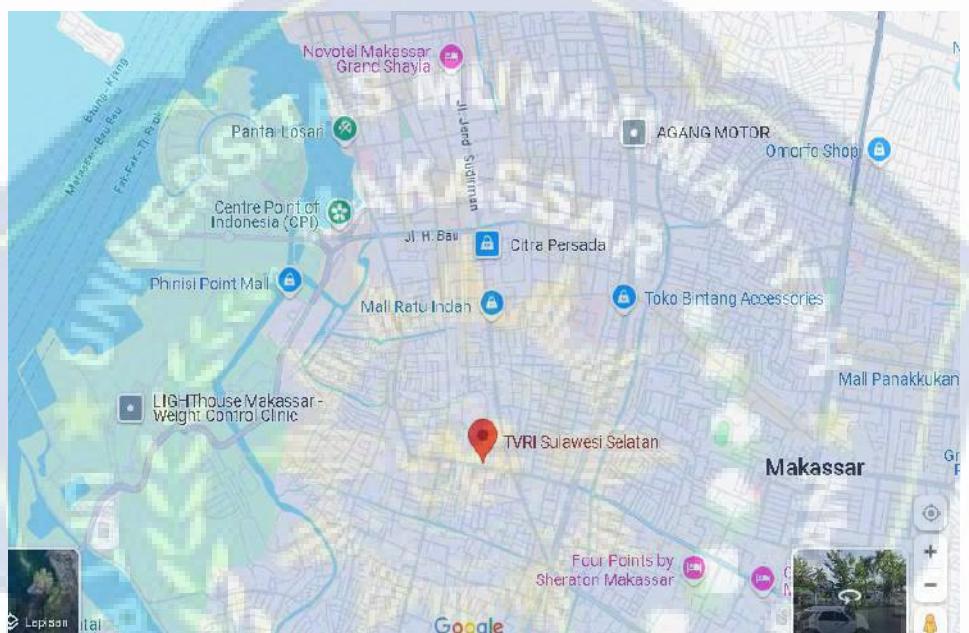
BAB III

METODOLOGI PENELITIAN

A. Tempat dan waktu Penelitian

1. Tempat

Penelitian ini Dilakukan pada Televisi Republik Indonesia (TVRI) Stasiun Makassar pada Divisi IT Inventaris, yang berlokasi di Jl. Pajonga Dg. Ngalle No.14, Mario, Kec. Mariso,Kota Makassar, Sulawesi Selatan 90122



Gambar 2. Lokasi Penelitian TVRI Stasiun

2. Waktu Penelitian

Penelitian ini di lakukan pada Bulan Mei 2025. Kegiatan ini dimulai dengan studi literatur berlangsung selama minggu kedua 2025. Setelah itu, dilakukan penyusunan skripsi yang dimulai minggu kedua dan berlanjut hingga minggu keempat. Kegiatan pengumpulan data dilaksanakan selama minggu pertama Bulan Juni, kemudian dilanjutkan dengan pengolahan data pada minggu kedua hingga minggu ketiga Juni, selanjutnya disusul dengan pengujian sistem pada minggu ketiga Bulan Juni. Terakhir, Penyusunan laporan akhir dilakukan pada minggu keempat Juni 2025, hingga bulan Juli minggu pertama sebagai tahap akhir dari keseluruhan proses penelitian ini.

B. Alat dan bahan

1. Bahan penelitian

Data transaksi peminjaman barang di TVRI Sulawesi selatan divisi IT
Inventaris

2. Kebutuhan *Hardware* (Perangkat Keras)

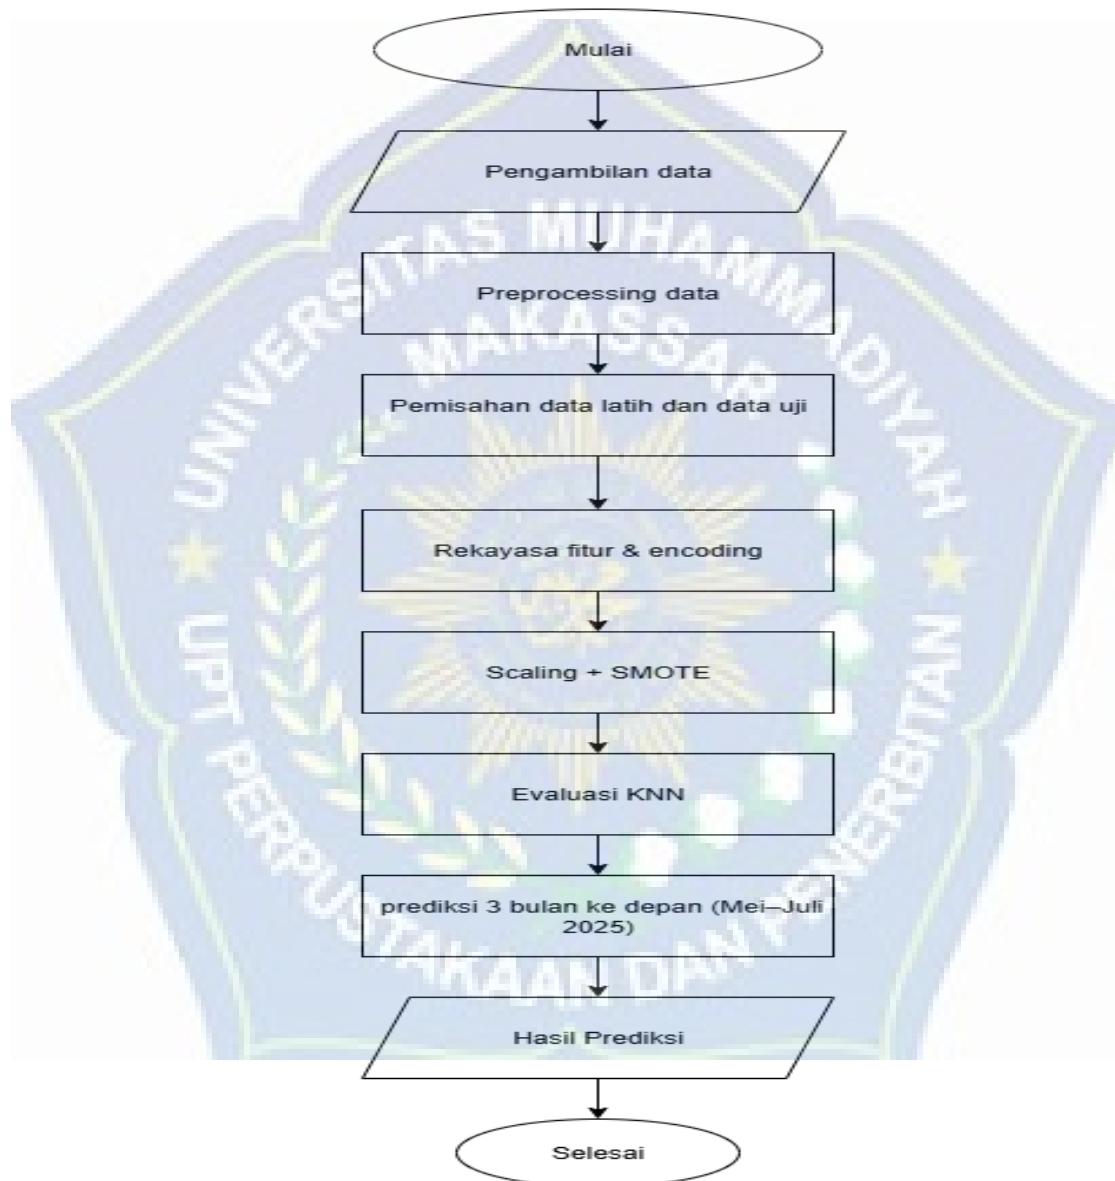
Laptop *Acer Aspire 3* dengan prosesor *AMD Ryzen 5*, RAM 8GB, dan SSD 250GB.

3. Kebutuhan *Software* (Perangkat Lunak)

- a. Github *Codespaces* atau Visual Studio Code Sebagai lingkungan pengembangan (*Integrated Development Environment*, IDE) yang digunakan untuk menulis, menjalankan, dan mengelola kode program.
- b. *Python* Bahasa pemrograman utama yang digunakan untuk membangun sistem prediksi.
- c. *Microsoft Excel* Untuk melakukan pemeriksaan awal, *praproses* manual, dan validasi data dari format CSV.
- d. *pandas* Untuk membaca, memproses, dan memanipulasi data *tabular* dari file CSV.
- e. *NumPy* Untuk pengolahan data numerik, operasi vektor, dan manipulasi *array*.
- f. *scikit-learn* Digunakan untuk penerapan algoritma *K-Nearest Neighbor* (KNN), optimasi parameter dengan *GridSearchCV*, *preprocessing* data seperti Label Encoding dan Standard Scaling, serta evaluasi kinerja model melalui metrik akurasi, *classification report*, dan *confusion matrix*.
- g. *imblearn (SMOTE)* Untuk mengatasi ketidakseimbangan kelas pada data (*imbalanced dataset*) dengan melakukan sintesis data minoritas.
- h. *matplotlib* Untuk visualisasi data, grafik tren peminjaman, dan tampilan *confusion matrix*.
- i. Koneksi Internet/Wi-Fi Diperlukan jika menggunakan Github Codespaces atau ingin mengunduh *dependency* melalui *package manager* seperti *pip*.

C. Perancangan Sistem

Flowchart adalah diagram yang menggambarkan opsi dan langkah-langkah yang diperlukan untuk menyelesaikan suatu proses dalam program, yang dikenal sebagai diagram alur. Setiap langkah dijelaskan dalam diagram tersebut, dengan garis atau panah yang menghubungkan setiap tahap



Gambar 3. Perancangan Sistem

1. Pengambilan Data Histori Peminjaman merupakan langkah awal pengumpulan bahan dasar penelitian. Data mentah mengenai transaksi peminjaman barang inventaris akan diperoleh dari sistem pencatatan atau arsip yang dikelola oleh

Divisi Inventaris TVRI Makassar. Data ini diasumsikan berbentuk tabel Excel yang sebelumnya berbentuk buku manual dan akan dikompilasi menjadi satu data set awal yang akan menjadi input untuk tahap selanjutnya. Ketersediaan dan kelengkapan data dari sumber ini akan sangat menentukan kualitas analisis.

Pengolahan Data (*Preprocessing Data*)

2. Pra-Pengolahan Data (*Preprocessing Data*), Data mentah jarang sekali langsung siap untuk dianalisis oleh algoritma *machine learning*. Oleh karena itu, tahap ini sangat krusial untuk membersihkan, mentransformasi, dan menyiapkan data agar berkualitas dan sesuai format untuk algoritma KNN. Langkah-langkah detailnya meliputi Data mentah jarang sekali langsung siap untuk dianalisis oleh algoritma *machine learning*. Oleh karena itu, tahap ini sangat krusial untuk membersihkan, mentransformasi, dan menyiapkan data agar berkualitas dan sesuai format untuk algoritma KNN. Langkah-langkah detailnya meliputi
 - a. Pembersihan Data
 - 1) Penanganan Nilai Hilang (*Missing Values*) Mengidentifikasi kolom dan baris yang memiliki data kosong. Bergantung pada jumlah dan pola data yang hilang, strategi yang dapat diterapkan adalah penghapusan baris data tersebut (jika jumlahnya sedikit dan tidak signifikan) atau *imputasi* (mengisi nilai hilang dengan nilai statistik seperti modus untuk data kategorikan, atau median/rata-rata untuk numerik jika ada).
 - 2) Penanganan Inkonsistensi Memeriksa dan memperbaiki data yang tidak konsisten, misalnya variasi penulisan nama barang yang sama ("Kamera Sony" vs "kamera Sony"), format tanggal yang berbeda, atau kesalahan entri lainnya. Ini memerlukan standarisasi data, misalnya dengan membuat pemetaan (*mapping*) untuk nama barang.
 - 3) Penanganan Duplikasi Data Memeriksa dan menghapus baris data yang merupakan duplikat identik dari data lain.

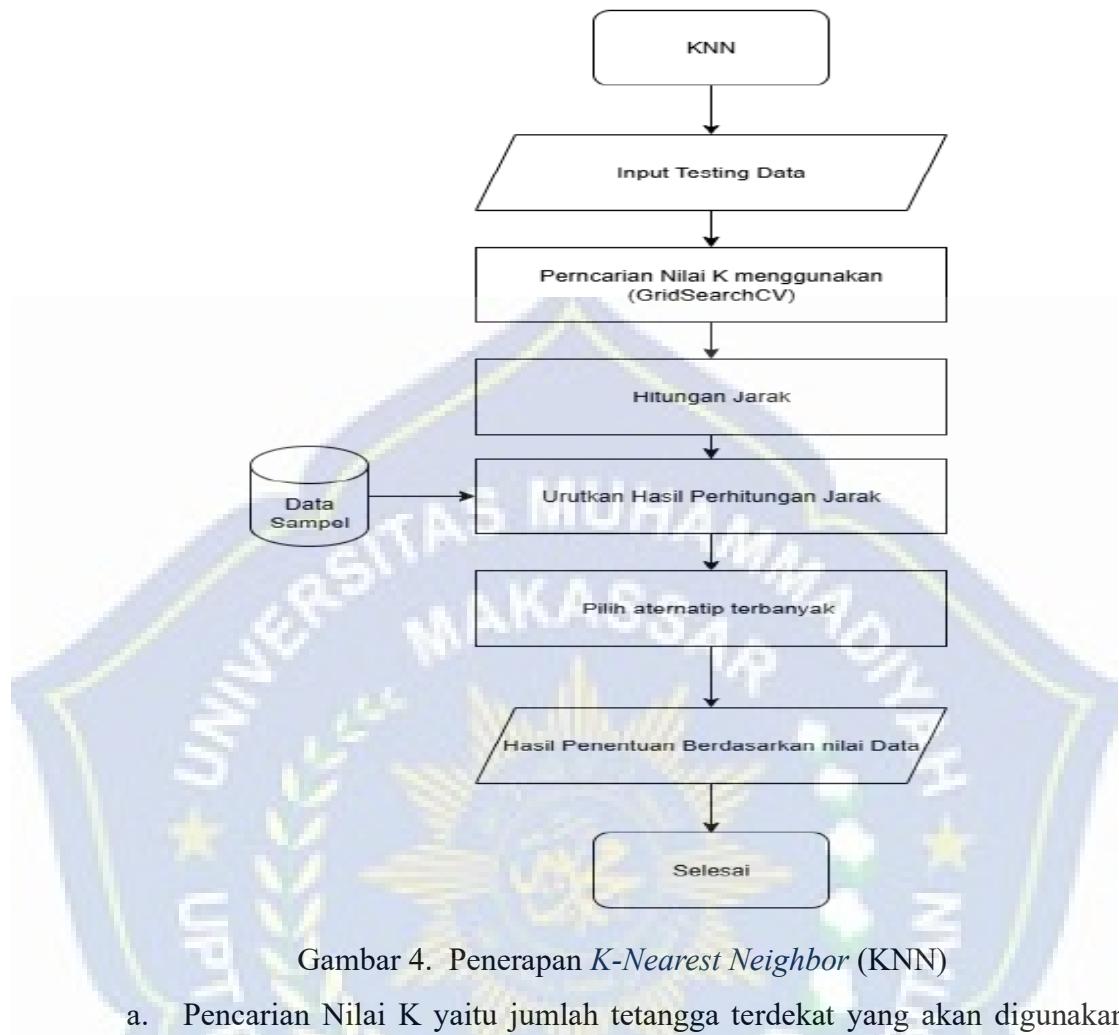
b. Transformasi Data

- 1) *Encoding* Fitur Kategorikan Algoritma KNN bekerja berdasarkan perhitungan jarak numerik. Oleh karena itu, fitur non-numerik (kategorikan) seperti Nama Barang atau Unit Peminjam perlu diubah menjadi representasi numerik. Metode yang umum digunakan adalah *Label Encoding* (memberikan nomor unik untuk setiap kategori) atau *One-Hot Encoding* (membuat kolom biner baru untuk setiap kategori unik). Pemilihan metode tergantung pada sifat data dan jumlah kategori.
 - 2) *Feature Engineering (Jika Relevan)* Membuat fitur baru dari data yang ada yang mungkin lebih informatif untuk model. Contohnya, mengekstrak Bulan atau Hari dalam Seminggu dari fitur Tanggal Peminjaman untuk menangkap potensi pola musiman peminjaman.
 - 3) *Normalisasi/Standarisasi Fitur Numerik* Jika terdapat fitur numerik (selain hasil *encoding*) yang memiliki rentang nilai sangat berbeda, perlu dilakukan penyesuaian skala. KNN sangat sensitif terhadap skala fitur karena perhitungan jaraknya. Metode yang umum adalah *Min-Max Saling* (menykalakan ke rentang [0, 1]) atau *Standardization (Z-score)* (mengubah data sehingga memiliki rata-rata 0 dan standar deviasi 1).
- c. Seleksi Fitur (Jika Diperlukan) Setelah transformasi, mungkin terdapat banyak fitur. Langkah ini melibatkan pemilihan fitur-fitur yang dianggap paling relevan atau paling berkontribusi terhadap prediksi barang yang dipinjam, dan mengabaikan fitur yang kurang informatif atau renungan.
- 1) Hasil akhir dari tahap ini adalah data set yang bersih, terstruktur, dan seluruhnya dalam format numerik yang siap untuk dibagi dan dimasukkan ke dalam model KNN.
 - 2) Pembersihan data (menangani mesing *values*, inkonsistensi).
 - 3) Transformasi data (*encoding* data kategorikan ke numerik, *feature Engineering* jika diperlukan, normalisasi/standarisasi fitur numerik).

3. Pemisahan Data Latih dan Data Uji Pembagian Data untuk Pengujian Data

Sebelum model dibangun, Data set yang telah melalui para-pengolahan akan dibagi menjadi dua subjek utama:

- a. Data Latih (*Testing Set*) Digunakan oleh algoritma KNN untuk mempelajari pola dari data historis (dalam kasus KNN, data ini disimpan untuk perbandingan). Proporsi umum yang akan dipertimbangkan adalah 70-80% dari total data set.
 - b. Penerapan *Smote* pada *training* untuk mengatasi masalah tidak keseimbangan kelas, teknik *Smote* diterapkan pada *dataset* yang telah di lakukan pembagian data. Proses ini menyeimbangkan distribusi kelas dengan membuat sampel sintetis untuk kelas-kelas minoritas.
 - c. Data Uji (*Testing Set*) Digunakan secara eksklusif untuk menguji kinerja model setelah dilatih. Data ini benar-benar independen dari data latih dan mencerminkan data baru yang belum pernah dilihat model. Proporsinya adalah sisa dari data set (20-30%).
4. Penerapan KNN untuk Prediksi 3 Bulan berikutnya, *K-Nearest Neighbor (KNN)* merupakan salah satu metode klasifikasi berbasis *instance-based learning* yang bekerja dengan prinsip kedekatan jarak. Artinya, suatu data uji akan ditentukan kelasnya dengan membandingkannya terhadap data latih yang sudah ada. Proses ini melibatkan beberapa tahap, mulai dari memasukkan data uji, menentukan nilai parameter *k* yang paling optimal, menghitung jarak antara data uji dengan data latih, hingga melakukan voting berdasarkan mayoritas tetangga terdekat. *Flowchart* berikut menggambarkan alur kerja KNN secara sistematis, mulai dari input data, pencarian nilai *k* menggunakan *GridSearchCV*, perhitungan jarak, pengurutan tetangga, pemilihan kelas terbanyak, hingga menghasilkan keputusan akhir. Dengan adanya diagram alur ini, proses klasifikasi KNN dapat lebih mudah dipahami secara visual dan logis.



Gambar 4. Penerapan *K-Nearest Neighbor* (KNN)

- Pencarian Nilai K yaitu jumlah tetangga terdekat yang akan digunakan dalam proses prediksi. Pencarian nilai K menggunakan teknik seperti *GridSearch* untuk mencari nilai terbaik.
- Hitung Jarak antara data uji dan semua data latih sampel menggunakan rumus antara *Euclidean* atau Jarak *Manhattan*
- Perhitungan Jarak Semua hasil jarak yang dihitung diurutkan dari yang paling dekat hingga paling jauh. Langkah ini penting untuk memilih K data tetangga terdekat.
- Pilih Alternatif terbanyak dari K tetangga terdekat tersebut, dipilih berdasarkan hasil dari *GridSearch* sebagai hasil prediksi.
- Hasil Penentuan Berdasarkan Nilai Data uji akhirnya diklasifikasikan atau diprediksi ke dalam kelas tertentu berdasarkan hasil voting dari tetangga terdekat tersebut.

D. Teknik Pengujian Sistem

Pengujian sistem dalam penelitian ini bertujuan untuk mengevaluasi secara kuantitatif dan objektif sejauh mana model *K-Nearest Neighbor* (KNN) yang telah dibangun dan dioptimalkan mampu melakukan klasifikasi secara akurat pada data yang belum pernah dilihat sebelumnya (data uji). Tahap ini krusial untuk memvalidasi keandalan model dan menjawab rumusan masalah mengenai tingkat akurasi. Teknik pengujian sistem yang akan diterapkan adalah sebagai berikut:

1. Pembagian Data untuk Pelatihan dan Pengujian (*Data Splitting*)

Sebelum pemodelan, *dataset* yang telah melalui tahap *pra-pengolahan* dibagi menjadi dua subset utama menggunakan fungsi *train_test_split* dari *Scikit-learn*

- a. Data Latih (*Training Set*) Sebesar 80% dari total data, digunakan untuk proses optimasi dan pelatihan model.
- b. Data Uji (*Testing Set*) Sebesar 20% dari total data, disimpan secara terpisah dan hanya digunakan untuk evaluasi final setelah model selesai dilatih.

Parameter *stratify* digunakan selama pembagian untuk memastikan bahwa proporsi setiap kelas (alat) pada data latih dan data uji sama dengan proporsi pada data set asli, yang penting untuk evaluasi yang valid pada data tidak seimbang.

2. Optimasi Model dan Validasi Silang Menggunakan *GridSearchCV*

Untuk menemukan konfigurasi model K-NN yang paling optimal, penelitian ini tidak menggunakan satu set parameter tetap, melainkan menerapkan proses pencarian sistematis menggunakan *GridSearchCV*. Proses ini secara otomatis melakukan langkah-langkah berikut pada data latih:

- a. Validasi Silang Berstrata (*Stratified K-Fold Cross-Validation*) Data latih dibagi lagi menjadi 5 folds (lipatan). Teknik *StratifiedKFold* memastikan setiap *fold* memiliki proporsi kelas yang sama.
- b. Pencarian *Hiperparameter* *GridSearchCV* secara alteratif melatih dan mengevaluasi model K-NN dengan berbagai kombinasi *hiperparameter* yang telah ditentukan, seperti

- 1) *n_neighbors* (jumlah tetangga)
- 2) *weights* (metode pembobotan)
- 3) *metric* (metrik jarak)

Pemilihan Model Terbaik Berdasarkan rata-rata skor akurasi dari 5 *folds*, *GridSearchCV* akan mengidentifikasi kombinasi *hiperparameter* terbaik. Model K-NN dengan konfigurasi terbaik ini (*best_estimator_*) kemudian secara otomatis dilatih kembali menggunakan seluruh data latih dan siap untuk evaluasi final.

3. Evaluasi Kinerja Final pada Data Uji Model K-NN terbaik yang dihasilkan dari proses *GridSearchCV* kemudian diuji performanya pada data uji yang telah disisihkan. Kinerja model diukur secara komprehensif menggunakan fungsi-fungsi dari *library Scikit-learn*:
 - a. Akurasi (*accuracy_score*) Mengukur persentase keseluruhan Klasifikasi yang benar.
 - b. Laporan Klasifikasi (*classification_report*) Memberikan rincian metrik *Presisi, Recall, dan F1-Score* untuk setiap kelas. Metrik ini sangat penting untuk memahami performa model pada data yang tidak seimbang.
 - c. *Confusion Matrix* Divisualisasikan untuk menganalisis secara detail di mana model berhasil dan gagal dalam melakukan klasifikasi antar kelas.
4. Validasi Metodologis Melalui Perhitungan Manual

Untuk memastikan transparansi, memverifikasi konsistensi logika internal dari implementasi algoritma, dan membuktikan keakuratan hasil komputasi, serangkaian analisis konseptual melalui perhitungan manual akan dilakukan. Langkah ini tidak berfungsi sebagai metode evaluasi kinerja utama, melainkan sebagai verifikasi metodologis untuk menunjukkan bahwa logika komputasi sistem sesuai dengan teori matematis yang mendasarinya. Proses validasi manual ini akan mencakup dua area utama

- a. Validasi Akurasi dan Metrik Kinerja

Validasi ini bertujuan untuk membuktikan bahwa metrik-metrik (*Akurasi, Presisi, Recall, F1-Score, Spesifitas*) yang dilaporkan oleh program adalah benar dan dapat dipercaya. Prosesnya adalah sebagai berikut:

- 1) Rekonstruksi Komponen *Confusion Matrix* berdasarkan nilai-nilai yang disajikan dalam Laporan *Klasifikasi* yang dihasilkan program (yaitu, *Presisi*, *Recall*, dan *Support*), nilai-nilai fundamental seperti *True Positive (TP)*, *False Negative (FN)*, dan *False Positive (FP)* akan dihitung ulang secara manual untuk kelas studi kasus.
- 2) Verifikasi Ulang *Metrik Dengan* menggunakan nilai *TP*, *FN*, *FP*, dan *True Negative (TN)* yang telah direkonstruksi, semua metrik utama akan dihitung kembali menggunakan rumus matematisnya.
- 3) Hasil perhitungan manual ini kemudian akan dibandingkan dengan nilai yang dilaporkan oleh program. Kesesuaian antara keduanya akan mengonfirmasi keakuratan laporan kinerja.
 - b. Validasi Cara Kerja Inti Algoritma KNN
Validasi ini bertujuan untuk mendemonstrasikan pemahaman terhadap mekanisme internal KNN dan memverifikasi bahwa implementasi program berjalan sesuai dengan parameter optimal yang ditemukan. Prosesnya adalah sebagai berikut:
 - 1) Pemilihan Sampel Data Satu sampel data akan diambil secara acak dari data uji yang telah melalui proses *scaling* sebagai titik data baru yang akan diprediksi. Sejumlah kecil sampel (misalnya, 5 sampel) juga akan diambil dari data latih yang telah di-*scaling* dan di-*resampling* untuk bertindak sebagai "*database pengetahuan*".
 - 2) Penerapan Parameter Optimal Nilai 'k' (jumlah tetangga), metrik jarak, dan metode pembobotan yang digunakan dalam perhitungan manual akan sama persis dengan parameter optimal yang ditemukan oleh proses *GridSearchCV* (misalnya, $k=3$, *metric='euclidean'*, *weights='distance'*).
 - 3) Identifikasi 'k' Tetangga Terdekat Hasil perhitungan jarak akan diurutkan untuk mengidentifikasi 'k' sampel data latih dengan jarak terkecil.
 - 4) Penentuan Kelas Prediksi melalui Voting Berbobot Kelas dari 'k' tetangga terdekat akan diamati. Sesuai dengan parameter *weights='distance'*, suara dari setiap tetangga akan diberi bobot yang berbanding terbalik dengan jaraknya

- (Bobot = 1 / Jarak). Kelas yang memiliki total akumulasi bobot suara tertinggi akan ditetapkan sebagai hasil prediksi manual.
- 5) Verifikasi dengan Hasil Program Hasil prediksi dari perhitungan manual akan dibandingkan dengan hasil prediksi yang dikeluarkan oleh model program (*best_knn.predict*) untuk sampel data uji yang sama. Kesesuaian antara kedua hasil ini akan memberikan keyakinan bahwa logika komputasi yang diimplementasikan dalam sistem sudah berjalan konsisten dengan alur kerja matematis dari algoritma *K-Nearest Neighbor*.

E. Teknik Analisis Data

Teknik analisis data yang digunakan dalam penelitian ini berpusat pada penerapan Algoritma *K-Nearest Neighbor* (KNN), yang diimplementasikan menggunakan bahasa pemrograman *Python* beserta *library* utamanya seperti *Pandas*, *Scikit-learn*, dan *Imbalanced-learn*. Proses analisis data meliputi langkah-langkah sistematis berikut

1. Eksplorasi dan Pra-pengolahan Data

Analisis dimulai dengan eksplorasi data untuk memahami karakteristik dasarnya. Proses pra-pengolahan kemudian diterapkan untuk menyiapkan data agar optimal untuk pemodelan:

- a. Pembersihan dan Standardisasi Melakukan standardisasi nama alat untuk mengonsolidasi kategori, mengonversi format tanggal, dan menghapus data yang tidak valid atau memiliki nilai hilang.
- b. Rekayasa Fitur Membuat fitur-fitur baru yang informatif seperti Bulan, *Frekuensi Alat*, Hari Ke (hari dalam seminggu), dan Minggu_Ke (minggu dalam setahun) untuk menangkap pola peminjaman.
- c. *Encoding* dan *Normalisasi* Fitur *kategorikal* diubah menjadi numerik menggunakan *LabelEncoder*, dan semua fitur *numerik* dinormalisasi dengan *StandardScaler* untuk menyamakan skala.

2. Penanganan Tidak seimbang dan Pemodelan K-NN

Setelah data dipisahkan menjadi data latih dan uji, dilakukan penanganan ketidakseimbangan dan pemodelan

- a. Penerapan *SMOTE* Teknik *over-sampling* *SMOTE* diterapkan pada data latih untuk menyeimbangkan distribusi kelas. Langkah ini krusial untuk meningkatkan kemampuan model dalam mengenali kelas minoritas (barang yang jarang dipinjam).
- b. Optimasi *Hiperparameter* dengan *GridSearchCV* untuk menemukan model K-NN terbaik, dilakukan pencarian sistematis menggunakan *GridSearchCV* dengan validasi silang *StratifiedKFold*. Proses ini menguji berbagai kombinasi *hiperparameter* (*n_neighbors*, *weights*, *metric*) untuk mendapatkan konfigurasi dengan akurasi tertinggi.
- c. Pelatihan Model Final Model K-NN dengan *hiperparameter* terbaik kemudian dilatih menggunakan seluruh data latih yang telah diseimbangkan.

3. Evaluasi Kinerja Model

Kinerja model K-NN yang telah dioptimalkan dievaluasi secara kuantitatif pada data uji menggunakan metrik-metrik standar dari *Scikit-learn*:

- a. Akurasi Keseluruhan Menggunakan *accuracy score* untuk mengukur persentase prediksi yang benar.
- b. Laporan Klasifikasi Rinci Menganalisis *classification_report* yang berisi nilai *Presisi*, *Recall*, dan *F1-Score* untuk setiap kelas alat, guna memahami kekuatan dan kelemahan model pada masing-masing kategori.
- c. Analisis Visual dengan *Confusion Matrix* Membuat visualisasi *confusion Matrix* untuk mengidentifikasi secara spesifik di mana model sering melakukan kesalahan klasifikasi antar kelas.
- d. Untuk memberikan konteks dan mengukur nilai tambah dari model yang dikembangkan, kinerjanya (terutama akurasi) akan dibandingkan dengan model dasar yang selalu memprediksi kelas mayoritas dari data latih.

4. Analisis Prediktif dan Interpretasi Hasil

Model yang telah tervalidasi digunakan untuk melakukan analisis prediktif guna mengidentifikasi tren peminjaman barang selama tiga bulan ke depan.

- a. Model yang telah tervalidasi akan digunakan untuk mensimulasikan permintaan di masa depan. Proses ini tidak menghasilkan satu prediksi tunggal per hari, melainkan menjalankan serangkaian skenario. Untuk setiap hari dalam

periode simulasi yang secara historis memiliki probabilitas transaksi di atas 15%, program akan secara *alteratif* menjalankan 10 skenario prediksi. Selanjutnya, untuk meningkatkan keandalan, hasil dari skenario-skenario ini akan *difilter*, di mana hanya prediksi dengan tingkat kepercayaan (peluang) yang sangat tinggi yang akan dicatat sebagai output akhir."

- b. *Visualisasi Tren* Hasil dianalisis dan diinterpretasikan melalui Grafik *Time Series* Menampilkan estimasi tren peminjaman harian untuk setiap jenis barang.
- c. Penarikan Kesimpulan berdasarkan hasil evaluasi dan analisis tren, ditarik kesimpulan mengenai pola peminjaman dan diberikan rekomendasi strategis untuk manajemen inventaris di TVRI Makassar.



BAB IV

HASIL DAN PEMBAHASAN

A. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data peminjaman yang bersumber dari catatan historis transaksi peminjaman barang pada Divisi Inventaris TVRI Makassar. Data mentah dihimpun dari arsip pencatatan manual dan dikompilasi ke dalam format digital berupa *file CSV* (datarill.csv). Kumpulan data ini mencakup tiga kolom utama yang relevan untuk analisis, yaitu Tanggal Peminjaman, Nama Alat, dan Nama Peminjam. Total data mentah yang berhasil dikumpulkan mencakup seluruh transaksi yang tercatat dalam periode tahun 2023 bulan Mei sampai tahun 2025 bulan April. Untuk menyajikan sampel dari data mentah sebelum dilakukan proses pengolahan lebih lanjut dapat ditampilkan ada Tabel 4.1 berikut.

Tabel 2. Sampel Data Mentah Peminjaman Barang

Nama Peminjam	Nama Alat	Tanggal Peminjaman	Nama Petugas	Tanggal Pengembalian	status pengembalian
Rinus	memori 256 gb	03/05/2023	Aswin	06/05/2023	sudah dikembalikan
Rinus	Camara	03/05/2023	Aswin	06/05/2023	sudah dikembalikan
Rinus	Lensa	03/05/2023	Aswin	06/05/2023	sudah dikembalikan
Rinus	memori 256 tuki 1	03/05/2023	Aswin	06/05/2023	sudah dikembalikan
Aji	Batrai	24/04/2025	Aswin	29/04/2025	sudah dikembalikan
Aji	soltion	24/04/2025	Aswin	29/04/2025	sudah dikembalikan
Aji	tripod camera	24/04/2025	Aswin	29/04/2025	sudah dikembalikan
Aji	canon	24/04/2025	Aswin	29/04/2025	sudah dikembalikan
Aji	ligting buah	24/04/2025	Aswin	29/04/2025	sudah dikembalikan

Data awal ini adalah data yang belum pernah di proses menjadi fondasi untuk seluruh tahapan analisis berikutnya, di mana kualitas dan kelengkapan data sangat menentukan akurasi hasil akhir.

B. Detail Pra-pemrosesan Data

Data mentah yang telah dikumpulkan tidak dapat langsung digunakan untuk pemodelan karena mengandung inkonsistensi, variasi penulisan, dan format yang belum sesuai untuk algoritma KNN. Oleh karena itu, dilakukan serangkaian tahap *pra-pemrosesan* data (*data preprocessing*) secara sistematis.

1. Penyederhanaan Nama Alat

Langkah awal adalah menyeragamkan variasi nama alat ke dalam kategori yang lebih umum. Proses ini bertujuan untuk mengurangi jumlah kelas target yang terlalu spesifik, sehingga model dapat mempelajari pola secara lebih efektif. Sebagai contoh, "*Camera Black Magic Pocket*" dan "*Kamera Sony*" disederhanakan menjadi kategori tunggal "*Camera*". Proses ini diimplementasikan melalui fungsi sederhanakan nama pada program. Tabel 4.2 menunjukkan perbandingan sebelum dan sesudah penyederhanaan.

Tabel 3. Contoh Penyederhanaan Nama Alat

Nama Alat (Sebelum)	Nama Alat <i>Simplified</i> (Sesudah)
<i>Black Magic Pocket Cinema Camera</i>	<i>Camera</i>
<i>Tripod Libek</i>	<i>Tripod</i>
<i>Baterai NP-F970</i>	<i>Battery</i>
<i>Godox SL60W</i>	<i>Lighting</i>
<i>Memori SD Card 128GB</i>	<i>Memory</i>

a. Pembersihan Data

Tahap ini meliputi beberapa tindakan krusial:

- 1) Penanganan Nilai Hilang Seluruh baris data yang tidak memiliki informasi lengkap, terutama pada kolom tanggal, nama alat, dan peminjam dihapus (*deleted*) untuk memastikan integritas data.
- 2) Standardisasi Format Tanggal Kolom Tanggal Peminjaman diubah menjadi format *datetime* yang konsisten untuk memungkinkan ekstraksi fitur temporal.
- 3) *Filtering* Kelas Minoritas Kelas (kategori alat) yang memiliki jumlah sampel di bawah ambang batas minimum (3 sampel) dihilangkan dari

dataset. Langkah ini penting untuk mencegah model menjadi bias dan memastikan setiap kelas memiliki representasi data yang cukup untuk proses pelatihan dan validasi.

b. Rekayasa Fitur (*Feature Engineering*)

Untuk memperkaya informasi yang dapat dipelajari oleh model, beberapa fitur baru diciptakan dari data yang ada:

- 1) Bulan Angka representasi bulan (1-12) dari tanggal peminjaman.
- 2) Hari Ke Angka representasi hari dalam seminggu (0 untuk Senin, 6 untuk Minggu).
- 3) Minggu Ke Angka representasi minggu dalam setahun.
- 4) Frekuensi Alat Jumlah total peminjaman untuk setiap kategori alat.
- 5) Peminjam *encoded* Representasi numerik dari nama peminjam menggunakan *Label Encoding*, sehingga setiap peminjam unik memiliki kode angka tersendiri.
- 6) Alat *encoded* Representasi numerik dari kategori alat (*Nama Alat Simplified*) menggunakan *Label Encoding*, sehingga setiap kategori alat memiliki kode angka unik.

Fitur-fitur ini dirancang untuk membantu model menangkap pola temporal (musiman, mingguan) dan popularitas item.

c. Standarisasi dan Penyeimbangan Kelas

- 1) *Split Data* Sebelum *SMOTE* data dibagi menjadi data latih (*train*) dan uji (*test*) terlebih dahulu. Hal ini mencegah data *leakage* dengan memastikan data uji tetap asli dan tidak terpengaruh sampel sintetis dari *SMOTE*.
- 2) Standarisasi Seluruh fitur numerik yang telah dibuat kemudian *distandarisasi* menggunakan *StandardScaler*. Proses ini mengubah skala setiap fitur sehingga memiliki rata-rata 0 dan standar deviasi 1. Standarisasi sangat penting untuk KNN karena algoritma ini berbasis jarak, dan fitur dengan rentang nilai yang besar dapat mendominasi perhitungan jarak.
- 3) Penyeimbangan Kelas data historis menunjukkan adanya tidak keseimbangan kelas, di mana beberapa alat (misalnya Kamera) jauh lebih sering dipinjam

dibanding yang lain (misalnya *Drone*). Untuk mengatasi hal ini, digunakan teknik *Synthetic Minority Over-sampling Technique (SMOTE)* pada data latih. Dalam implementasinya parameter *k_neighbors* SMOTE diatur secara adaptif yaitu min(5, jumlah minimal sampel kelas - 1), agar tetap bekerja meskipun kelas minoritas memiliki sedikit sampel. *SMOTE* bekerja dengan menciptakan sampel sintetis untuk kelas-kelas minoritas, sehingga distribusi kelas menjadi lebih seimbang dan model tidak cenderung hanya memprediksi kelas mayoritas.

C. Penerapan Metode *K-Nearest Neighbor* (KNN)

Setelah tahap *praproses* dan rekayasa fitur selesai dilakukan, algoritma *K-Nearest Neighbor* (KNN) diterapkan untuk membangun model prediksi. Data dibagi menjadi dua subset, yaitu 80% sebagai data latih (*training set*) dan 20% sebagai data uji (*testing set*), menggunakan fungsi *train_test_split* dengan parameter *stratify*. Penggunaan *stratification* bertujuan untuk menjaga distribusi proporsi kelas pada data latih dan data uji agar tetap seimbang, sehingga hasil evaluasi model menjadi lebih representatif.

a. Optimasi *Hyperparameter*

Pemilihan *hyperparameter* yang tepat merupakan faktor krusial dalam mengoptimalkan kinerja model. Pada penelitian ini proses optimasi dilakukan secara otomatis menggunakan *Grid Search Cross-Validation (GridSearchCV)* dengan skema validasi silang (*cross-validation*) berlapis (*stratified*) sebanyak lima lipatan (5-fold). Pendekatan ini memastikan bahwa evaluasi model dilakukan secara menyeluruh pada berbagai *subset* data, sehingga mengurangi risiko *overfitting*. Adapun parameter yang digunakan dapat disajikan dalam Tabel 4.3 dan 4.4 berikut.

Tabel 4. Parameter yang digunakan

No	Parameter	Nilai
1	<i>n_neighbors</i>	[3, 5, 7, 9]
2	<i>Weights</i>	['uniform', 'distance']
3	<i>Metric</i>	['euclidean', 'manhattan']

Berdasarkan hasil *GridSearchCV*, konfigurasi model KNN terbaik yang ditemukan adalah

Tabel 5. Parameter terbaik yang digunakan

No	Parameter	Nilai
1	<i>n_neighbors</i>	[3]
2	<i>Weights</i>	['distance']
3	<i>Metric</i>	['euclidean']

Berdasarkan Tabel 4.3 dan 4.4 dijelaskan bahwa konfigurasi parameter yang memberikan kinerja terbaik pada model *K-Nearest Neighbor* (KNN). Parameter yang diuji meliputi jumlah tetangga terdekat (*n_neighbors*) dengan nilai 3, 5, 7, dan 9, metode pemberian bobot (*weights*) berupa '*uniform*' dan '*distance*', serta metrik pengukuran jarak (*metric*) yaitu '*euclidean*' dan '*manhattan*'. Pemilihan rentang nilai ini didasarkan pada praktik umum dalam algoritma KNN dan relevansi fitur yang digunakan. Hasil optimasi menunjukkan konfigurasi terbaik diperoleh dengan *n_neighbors* = 3, *weights* = '*distance*', dan *metric* = '*manhattan*'. Hal ini menandakan bahwa model mencapai performa optimal saat menggunakan tiga tetangga terdekat dengan bobot suara yang dipengaruhi oleh jarak (semakin dekat tetangga, semakin besar pengaruhnya) serta metrik jarak *Manhattan* yang sensitif terhadap perbedaan *absolut* antar fitur. Kombinasi parameter ini mampu memberikan keseimbangan yang baik antara sensitivitas lokal dan generalisasi model, sehingga meningkatkan akurasi prediksi dalam konteks *dataset* yang digunakan.

- b. Analisis pemilihan Parameter dan nilai K yang di gunakan *K-Nearest Neighbor* (KNN)

untuk mencari kombinasi parameter terbaik dari jumlah tetangga (*n_neighbors*), jenis bobot (*weights*), serta metrik jarak (*metric*) yang menghasilkan akurasi tertinggi secara konsisten. Hasil dari pengujian ini disajikan dalam bentuk gambar yang memperlihatkan nilai rata-rata skor uji (*mean_test_score*), standar

deviasi (*std_test_score*), serta peringkat akurasi (*rank_test_score*) pada setiap kombinasi parameter yang diuji.

Tabel 6. Pengujian Parameter

No	n_neig	weights	metric	mean_test_score	std_test_score
hbors					
1	3	<i>distance</i>	<i>euclidean</i>	0.954245	0.006373
2	5	<i>distance</i>	<i>euclidean</i>	0.947992	0.009349
3	7	<i>distance</i>	<i>euclidean</i>	0.947663	0.007311
4	9	<i>distance</i>	<i>euclidean</i>	0.939763	0.008364
5	3	<i>uniform</i>	<i>euclidean</i>	0.938118	0.012023
6	5	<i>uniform</i>	<i>euclidean</i>	0.910137	0.011153
7	7	<i>uniform</i>	<i>euclidean</i>	0.889723	0.009608
8	9	<i>uniform</i>	<i>euclidean</i>	0.853193	0.007388
9	3	<i>distance</i>	<i>manhattan</i>	0.947662	0.008023
10	5	<i>distance</i>	<i>manhattan</i>	0.944373	0.009836
11	7	<i>distance</i>	<i>manhattan</i>	0.944044	0.010558
12	9	<i>distance</i>	<i>manhattan</i>	0.938446	0.006467
13	3	<i>uniform</i>	<i>manhattan</i>	0.928902	0.012627
14	5	<i>uniform</i>	<i>manhattan</i>	0.898888	0.012892
15	7	<i>uniform</i>	<i>manhattan</i>	0.879193	0.011569
16	9	<i>uniform</i>	<i>manhattan</i>	0.857138	0.016719

Tabel ini menunjukkan hasil Pengujian Parameter dan hasil analisis nilai K yang membandingkan berbagai kombinasi parameter KNN berdasarkan akurasi rata-rata *cross-validation*. Dari tabel ini mendapatkan hasil bahwa kombinasi k = 3 dengan bobot *distance* dan metrik *euclidean* memberikan hasil terbaik dengan akurasi rata-rata tertinggi sebesar 95,44% dan standar deviasi yang sangat rendah, artinya model tidak hanya akurat tetapi juga stabil di setiap lipatan pengujian. Nilai k lainnya seperti 5 atau 7 memang mendekati, tetapi tetap sedikit lebih rendah akurasinya. Oleh karena itu, k = 3 dipilih karena

terbukti paling optimal dalam merepresentasikan pola data dan menghasilkan prediksi yang lebih konsisten.

c. Tiga tetangga terdekat *K-Nearest Neighbor* (KNN)

perlu dijelaskan bahwa analisis tetangga terdekat digunakan untuk memperlihatkan proses pengambilan keputusan KNN.

Gambar 7. Tetangga nilai k 3 terdekat

Tetangga	Label	Jarak
	Studikasus 1	0.0000
1	Lensa	0.0000
2	Lensa	0.0000
3	Lensa	0.0000
	Studikasus 2	
1	Lighting	0.0000
2	Lighting	0.0000
3	Lighting	0.0000
	Studikasus 3	
1	Battery	0.0000
2	Camera	0.7932
3	Battery	0.8670

Tabel jarak K terdekat pada algoritma *K-Nearest Neighbor* (KNN) menunjukkan hasil pencarian tiga tetangga terdekat ($K=3$) untuk setiap data uji berdasarkan nilai jaraknya terhadap data latih. Pada studi kasus pertama, seluruh tetangga memiliki label *Lensa* dengan jarak 0.0000, yang menandakan bahwa data uji identik dengan data latih dari kelas *Lensa*, sehingga prediksi KNN secara meyakinkan jatuh pada kelas tersebut. Pada studi kasus kedua, kondisi serupa terjadi di mana semua tetangga berlabel *Lighting* dengan jarak 0.0000, sehingga hasil klasifikasinya juga jelas mengarah pada kelas *Lighting*. Sementara itu, pada studi kasus ketiga, tetangga pertama memiliki label *Battery* dengan jarak 0.0000, tetangga kedua berlabel *Camera* dengan jarak 0.7932, dan tetangga ketiga kembali *Battery* dengan jarak 0.8670. Berdasarkan prinsip

majoritas, karena dua dari tiga tetangga terdekat berlabel *Battery*, maka data uji diklasifikasikan sebagai *Battery*. Dengan demikian, tabel ini menggambarkan bahwa keputusan KNN ditentukan oleh kombinasi kedekatan jarak dan dominasi label dari tetangga terdekat.

d. Evaluasi Model

Model akhir yang telah melalui rangkaian proses pelatihan dan optimasi kemudian diuji menggunakan data uji yang belum pernah dikenali oleh model sebelumnya. Hasil evaluasi menunjukkan bahwa model ini berhasil mencapai akurasi sebesar 80,18%, yang mengindikasikan bahwa model mampu memprediksi dengan benar sekitar delapan dari sepuluh permintaan peminjaman barang. Untuk memberikan konteks terhadap capaian ini, kinerja model dibandingkan dengan model dasar (*baseline*) yang secara konsisten memprediksi kelas mayoritas, yakni kategori 'Camera', yang mendominasi sekitar 18,5% dari data uji. Dengan demikian, peningkatan akurasi dari 18,5% pada model dasar menjadi 80,18% pada model akhir secara jelas menunjukkan bahwa penerapan alur kerja *machine learning* yang digunakan memberikan nilai tambah yang signifikan dan jauh melampaui tebakan sederhana, sehingga memperkuat keandalan dan efektivitas model dalam memprediksi pola peminjaman barang.

D. Analisis Mendalam Kinerja per Kelas

Meskipun akurasi keseluruhan memberikan gambaran umum pemahaman yang lebih mendalam memerlukan analisis pada tingkat setiap kategori alat. Hal ini dilakukan melalui *Confusion Matrix* dan Laporan Klasifikasi.

Tabel 8. Hasil Pengujian Sistem

Kelas	Presisi	Recall	F1-Score	Spesifisitas	Support
<i>Battery</i>	1.00	1.00	1.00	1.00	53
<i>Camera</i>	1.00	0.95	0.97	1.00	41
<i>Charger</i>	0.72	0.65	0.68	0.98	20
<i>Drone</i>	1.00	0.50	0.67	1.00	2
<i>Gimbal</i>	1.00	0.50	0.67	1.00	8
<i>Lens</i>	0.73	0.73	0.73	0.98	15
<i>Lighting</i>	0.74	0.88	0.80	0.98	16

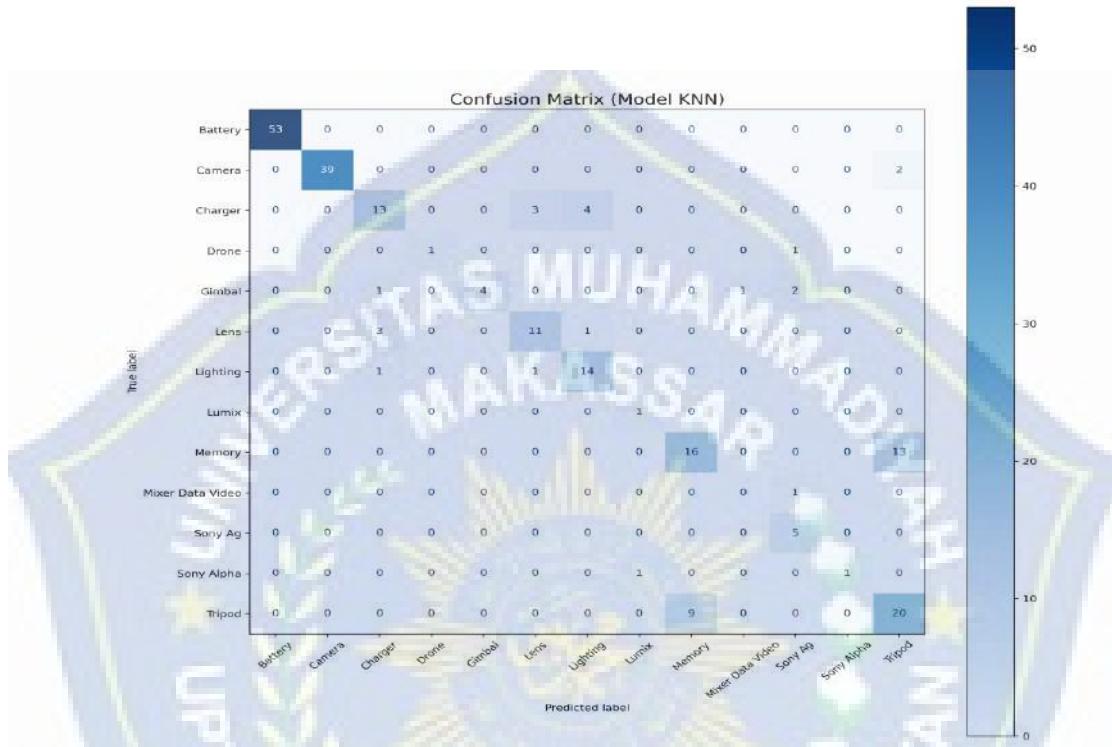
<i>Lumix</i>	0.50	1.00	0.67	1.00	1
<i>Memory</i>	0.64	0.55	0.59	0.95	29
<i>Mixer Data Video</i>	0.00	0.00	0.00	1.00	1
<i>Sony Ag</i>	0.56	1.00	0.71	0.98	5
<i>Sony Alpha</i>	1.00	0.50	0.67	1.00	2
<i>Tripod</i>	0.57	0.69	0.62	0.92	29

Tabel 9. laporan klasifikasi Matrix

Metrik	Presisi	Recall	F1-Score	Akurasi	Support
<i>Macro Avg</i>	0.73	0.69	0.68	-	222
<i>Weighted Avg</i>	0.82	0.80	0.80	-	222
<i>Overall</i>	-	-	-	0.80	222

Analisis nilai pada Tabel 4.5 mengindikasikan bahwa model KNN memiliki performa yang bervariasi antar kelas, tergantung pada jumlah dan distribusi data masing-masing kelas. Kelas dengan jumlah sampel besar seperti Battery dan Camera menunjukkan hasil sangat baik dengan presisi, *recall*, dan *F1-score* mendekati atau sama dengan 1.00, menandakan model sangat akurat dan mampu mengenali sampel dari kelas tersebut secara konsisten. Sebaliknya, kelas dengan jumlah data sangat sedikit, misalnya *Drone* dan *Mixer Data Video*, mengalami penurunan performa signifikan, terutama pada *recall* dan *F1-score*, yang menunjukkan model sering gagal mendeteksi benar sampel kelas tersebut. *Spesifisitas* yang tinggi pada hampir semua kelas menunjukkan bahwa model mampu menghindari kesalahan prediksi positif palsu, sehingga prediksi kelas lain tidak tercampur. Namun, ketidakseimbangan jumlah data antar kelas memengaruhi kemampuan model dalam mempelajari pola pada kelas minoritas, sehingga diperlukan teknik tambahan seperti penyeimbangan data untuk meningkatkan kinerja pada kelas tersebut. Secara keseluruhan, hasil ini mencerminkan efektivitas model dalam memprediksi kelas mayoritas dengan baik, tetapi masih ada ruang perbaikan untuk kelas dengan data terbatas.

- Analisis Visualisasi *confusion matrix* memungkinkan identifikasi kesalahan secara spesifik. Diagonal utama menunjukkan prediksi yang benar sementara sel di luar diagonal menyoroti di mana model melakukan kesalahan klasifikasi (misalnya, berapa kali 'Camera' keliru diprediksi sebagai 'Lensa').



Gambar 5. Confusion Matrix Model KNN

Analisis *confusion matrix* pada gambar di atas menunjukkan bagaimana model KNN melakukan klasifikasi terhadap berbagai kategori alat. Diagonal utama *matrix*, yang merepresentasikan prediksi yang benar untuk setiap kelas, terlihat jumlah yang cukup besar, khususnya untuk kelas Battery (53), Camera (39), dan Tripod (20), yang menunjukkan performa klasifikasi yang baik pada kelas-kelas tersebut. Namun, terdapat sejumlah kesalahan klasifikasi yang terlihat dari nilai-nilai di luar diagonal, misalnya kelas Charger yang sebagian prediksinya salah diklasifikasikan sebagai Memory dan Lens, serta kelas Memory yang beberapa sampelnya salah diklasifikasikan sebagai Tripod. Hal ini mengindikasikan adanya tumpang tindih fitur antar kelas tertentu sehingga model kadang kesulitan membedakan kelas-kelas tersebut. Beberapa kelas minoritas seperti Mixer Data

Video dan *Lumix* juga menunjukkan prediksi yang kurang akurat dengan nilai prediksi benar sangat rendah atau nol. Secara keseluruhan, *confusion matrix* ini mengonfirmasi bahwa model bekerja efektif pada kelas mayoritas dengan jumlah data cukup, namun performa menurun pada kelas minoritas yang memiliki data terbatas atau fitur yang kurang representatif.

Hasil evaluasi model menunjukkan bahwa secara keseluruhan model memiliki akurasi sebesar 80%, yang menandakan bahwa model mampu memprediksi dengan benar sekitar delapan dari sepuluh data. Dari segi rata-rata makro, presisi mencapai 0,73, *recall* 0,69, dan *F1-score* 0,68, yang menunjukkan bahwa performa model secara rata-rata per kelas masih cukup baik, namun ada perbedaan yang cukup signifikan antara presisi dan *recall*. Hal ini mengindikasikan bahwa model cenderung lebih tepat dalam memprediksi kelas positif (sedikit *false positives*), namun masih ada beberapa data positif yang terlewat (*false negatives*). Sementara itu, rata-rata tertimbang (*weighted average*) memberikan nilai presisi, *recall*, dan *F1-score* yang lebih tinggi, masing-masing sebesar 0,82, 0,80, dan 0,80. Ini menandakan bahwa model memiliki performa yang lebih baik pada kelas-kelas dengan jumlah data lebih banyak, sehingga nilai ini lebih mencerminkan kinerja model secara keseluruhan pada distribusi data yang tidak seimbang. Secara umum, model ini sudah menunjukkan performa yang baik, namun ada ruang untuk peningkatan terutama dalam hal meningkatkan *recall* pada kelas minoritas agar model tidak melewatkannya terlalu banyak data penting.

E. Perhitungan Manual Akurasi

Untuk memastikan transparansi dan memvalidasi keakuratan hasil komputasi ini dilakukan perhitungan manual sebagai studi kasus.

1. Validasi Akurasi Keseluruhan

Akurasi dihitung dengan membagi jumlah prediksi yang benar (*True Positives*) dengan jumlah total sampel. *True Positives* (TP) untuk setiap kelas dihitung menggunakan

$$TP = Recall \times Support \quad (8)$$

a. Perhitungan *True Positive* per Kelas

Tabel 10. Perhitungan *True Positive* per kelas

No.	Kategori	Nilai (x)	Jumlah	Perhitungan	Hasil
1	Battery	1.00	53	1.00×53	53
2	Camera	0.95	41	0.95×41	39
3	Charger	0.65	20	0.65×20	13
4	Drone	0.50	2	0.50×2	1
5	Gimbal	0.50	8	0.50×8	4
6	Lens	0.73	15	0.73×15	11
7	Lighting	0.88	16	0.88×16	14
8	Lumix	1.00	1	1.00×1	1
9	Memory	0.55	29	0.55×29	16
10	Mixer	Data	0.00	0.00×1	0
	Video				
11	Sony Ag	1.00	5	1.00×5	5
12	Sony Alpha	0.50	2	0.50×2	1
13	Tripod	0.69	29	0.69×29	20

2. Jumlah Prediksi Benar (Total *True Positive*)

$$53 + 39 + 13 + 1 + 4 + 11 + 14 + 1 + 16 + 0 + 5 + 1 + 20 = 178$$

3. Perhitungan Akurasi

$$\text{Akurasi} = \frac{178}{222} = 0.8018$$

a. Studi Kasus Validasi Menyeluruh (Kelas 'Tripod')

Untuk menunjukkan konsistensi laporan, kita validasi semua metrik utama untuk kelas 'Tripod' menggunakan nilai dari laporan.

1) Perhitungan Komponen *Confusion Matrix*

- a) Untuk kategori Tripod, *TP* merupakan jumlah peminjaman Tripod yang berhasil diprediksi dengan benar sebagai Tripod oleh model KNN. Nilai ini menjadi indikator langsung tingkat keberhasilan model dalam mengenali

peminjaman Tripod secara tepat. Berdasarkan definisi *recall*, nilai TP dihitung sebagai

$$TP = Recall \times Support = 0,69 \times 29 = 20,01$$

Artinya, terdapat 20 data peminjaman Tripod yang berhasil diidentifikasi secara benar oleh model.

- b) *False Negative (FN)* FN adalah jumlah kasus Tripod aktual yang gagal terdeteksi oleh model, atau dengan kata lain, diprediksi sebagai kategori lain. Nilai FN diperoleh dari selisih antara total kasus positif aktual (*support*) dengan TP

$$FN = Support - TP = 29 - 20 = 9$$

FN yang tinggi menunjukkan model sering melewatkannya peminjaman Tripod dalam prediksinya.

- c) FP menunjukkan jumlah peminjaman yang bukan Tripod namun diprediksi sebagai Tripod oleh model. Berdasarkan definisi *precision*, nilai FP dapat dihitung dari

$$Precision = \frac{TP}{TP+FP} \Rightarrow FP = \frac{TP}{Precision} - TP \quad (9)$$

Sehingga

$$FP = \frac{20}{0.57} - 20 = 15.08$$

FP yang tinggi akan menurunkan nilai *precision*, yang berarti model kurang selektif dalam menetapkan prediksi Tripod.

- d) TN adalah jumlah data peminjaman yang bukan Tripod dan tidak diprediksi sebagai Tripod oleh model. Nilainya dihitung sebagai

$$TN = Total Sampel - (TP + FN + FP) = 222 - (20 + 9 + 15) = 178$$

TN yang besar menunjukkan model cukup andal dalam menghindari kesalahan prediksi Tripod pada barang yang sebenarnya bukan Tripod.

2) Verifikasi Ulang Metrik

- a) *Recall* mengukur kemampuan model untuk mendeteksi seluruh kasus positif aktual, dalam hal ini peminjaman Tripod. Nilainya dihitung sebagai rasio antara *True Positive (TP)* dan jumlah seluruh kasus positif aktual (*TP + FN*):

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{20}{20 + 9} = \frac{20}{29} = 0.689$$

Interpretasi Model mampu mengenali sekitar 69% dari seluruh peminjaman Tripod yang benar-benar terjadi.

- b) *Precision* mengukur ketepatan prediksi model, yaitu proporsi prediksi Tripod yang benar-benar Tripod secara aktual. Dihitung sebagai

$$\frac{TP}{TP + FP} = \frac{20}{20 + 15} = \frac{20}{35} = 0.571$$

Interpretasi: Dari seluruh prediksi Tripod yang diberikan model, hanya sekitar 57% yang benar-benar sesuai dengan data aktual.

- c) *Specificity* atau *True Negative Rate* mengukur kemampuan model untuk mengidentifikasi dengan benar data yang bukan Tripod. Nilainya dihitung sebagai:

$$\text{Spesifisitas} = \frac{TN}{TN + FP} = \frac{178}{178 + 15} = \frac{178}{193} = 0.922$$

Interpretasi Model dapat mengenali barang yang bukan Tripod dengan tingkat ketepatan sekitar 92%, sehingga risiko kesalahan prediksi Tripod pada barang non-Tripod relatif rendah.

Kesimpulan Validasi Hasil perhitungan ulang menunjukkan bahwa seluruh metrik utama yang dilaporkan untuk kelas *Tripod* telah konsisten secara matematis. Nilai yang diperoleh dari perhitungan manual identik (perbedaan hanya pada pembulatan desimal) dengan yang dihasilkan oleh perangkat lunak, sehingga dapat dipastikan tidak terdapat ketidaksesuaian pada laporan evaluasi untuk kelas ini.

3) *F1-Score*

F1-score merupakan metrik harmonisasi antara *Recall* dan *Precision*, yang memberikan penilaian seimbang terhadap kemampuan model mendeteksi kasus positif sekaligus menjaga ketepatan prediksi. Rumusnya adalah

$$F1\text{-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (10)$$

Dengan nilai *Precision* = 0,57 dan *Recall* = 0,69, diperoleh

$$F1\text{-score} = 2 \times \frac{0.57 \times 0.69}{0.57 + 0.69}$$

$$\begin{aligned}
&= 2 \times \frac{0.3933}{1.26} \\
&= 2 \times 0.3122 \\
&= 0.624
\end{aligned}$$

Nilai *F1-score* sebesar 0,62 menunjukkan bahwa model memiliki keseimbangan moderat antara kemampuan menemukan peminjaman Tripod (*recall*) dan ketepatan prediksi (*precision*). Nilai ini mengindikasikan bahwa meskipun model cukup baik dalam mendeteksi Tripod, masih terdapat ruang untuk meningkatkan ketepatan prediksinya.

F. Perhitungan Manual *K-Nearest Neighbor* (KNN)

Untuk memberikan gambaran konkret mengenai mekanisme kerja algoritma *K-Nearest Neighbor* (KNN) yang digunakan dalam penelitian ini, berikut disajikan studi kasus perhitungan manual pada satu data uji. Pemilihan contoh ini bertujuan untuk memverifikasi kesesuaian hasil prediksi model dengan logika dasar KNN.

1. Sampel Data

Ambil 1 baris pertama dari data uji sebagai titik data baru yang akan diprediksi, dan 5 baris pertama dari data latih sebagai referensi.

- a. *Peminjam_encoded* : -0.2577
- b. Bulan : 0.9866
- c. *Frekuensi Alat* : 1.3441

Tabel 11. data Latih 5 Baris Pertama

ID	Peminjam encoded	Bulan	Frekuensi Alat	Kelas (Alat encoded)
1	-1.2706	0.3736	-0.1313	13
2	1.0086	-1.1589	-1.6225	4
3	-0.3843	0.0671	-0.8134	2
4	-0.2577	-1.7719	-1.1624	5
5	1.5784	-0.5459	-1.1624	5

2. Hitung Jarak *Euclidean*

Jarak *Euclidean* diukur antara titik data uji dan setiap titik data latih untuk menentukan kedekatan dalam ruang berdimensi n. Rumus umum jarak *Euclidean* adalah

$$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (11)$$

dengan:

- a) p : vektor data uji
- b) q : vektor data latih
- c) n : jumlah fitur atau dimensi

Perhitungan untuk setiap titik adalah sebagai berikut:

1) Jarak ke A

$$\begin{aligned} d &= \sqrt{(-0.2577 - (-1.2706))^2 + (0.9866 - 0.3736)^2 + (1.3441 - (-0.1313))^2} \\ &= 1.8917 \end{aligned}$$

2) Jarak ke B

$$\begin{aligned} d &= \sqrt{(-0.2577 - 1.0086)^2 + (0.9866 - (-1.1589))^2 + (1.3441 - (-1.6225))^2} \\ &= 3.8739 \end{aligned}$$

3) Jarak ke C

$$\begin{aligned} d &= \sqrt{(-0.2577 - (-0.3843))^2 + (0.9866 - 0.0671)^2 + (1.3441 - (-0.8134))^2} \\ &= 2.3487 \end{aligned}$$

4) Jarak ke D

$$\begin{aligned} d &= \sqrt{(-0.2577 - (-0.2577))^2 + (0.9866 - (-1.7719))^2 + (1.3441 - (-1.1624))^2} \\ &= 3.7272 \end{aligned}$$

5) Jarak ke E

$$\begin{aligned} d &= \sqrt{(-0.2577 - 1.5784)^2 + (0.9866 - (-0.5459))^2 + (1.3441 - (-1.1624))^2} \\ &= 3.4644 \end{aligned}$$

3. Temukan Tetangga Terdekat ($k=3$)

Pada tahap ini dilakukan identifikasi k tetangga terdekat sesuai nilai k hasil optimasi melalui *GridSearchCV*, yaitu $k = 3$.

1) Melakukan Voting Berbobot

Karena parameter model menggunakan *weights='distance'*, setiap tetangga memberikan suara dengan bobot yang proporsional terhadap kebalikan jarak (*inverse* jarak). Bobot suara masing-masing tetangga dihitung dengan rumus

$$w_i = \frac{1}{d_i} \quad (12)$$

Dengan di adalah jarak tetangga ke-i terhadap data uji. Hasil perhitungannya:

- a) Data A (Kelas 13) $\frac{1}{1.8917} = 0.5286$ \[4pt]
 - b) Data C (Kelas 2) $\frac{1}{2.3487} = 0.4257$ \[4pt]
 - c) Data E (Kelas 5) $\frac{1}{3.4644} = 0.2886$
- 2) Menentukan Kelas Prediksi

Kelas dengan total bobot suara terbesar dipilih sebagai hasil klasifikasi. Dalam contoh ini, kelas 13 memiliki bobot tertinggi 0.5286, sehingga data uji diklasifikasikan ke kelas 13. Prosedur ini secara eksplisit menggambarkan mekanisme internal algoritma *K-Nearest Neighbor* dengan pembobotan jarak, yang diimplementasikan identik di dalam program penelitian.

G. Analisis Visualisasi Hasil Prediksi

Model yang telah dievaluasi kemudian digunakan untuk menyimulasikan permintaan peminjaman harian selama tiga bulan ke depan (Mei, Juni, dan Juli 2025). Hasil dari simulasi ini divisualisasikan untuk mengidentifikasi tren permintaan, baik secara agregat bulanan maupun dalam fluktuasi harian yang lebih detail.

1. Analisis Data Mentah Hasil Simulasi

Selain visualisasi grafis program juga menghasilkan file hasil_prediksi_harian_difilter.csv yang berisi data mentah dari setiap prediksi individual yang berhasil melewati ambang batas peluang (99%). Data ini adalah fondasi dari semua grafik dan agregasi yang disajikan sebelumnya. Menganalisis sampel data ini memberikan wawasan tentang *output* model pada tingkat paling granular.

Tabel 12. *output* prediksi barang 3 bulan ke depan

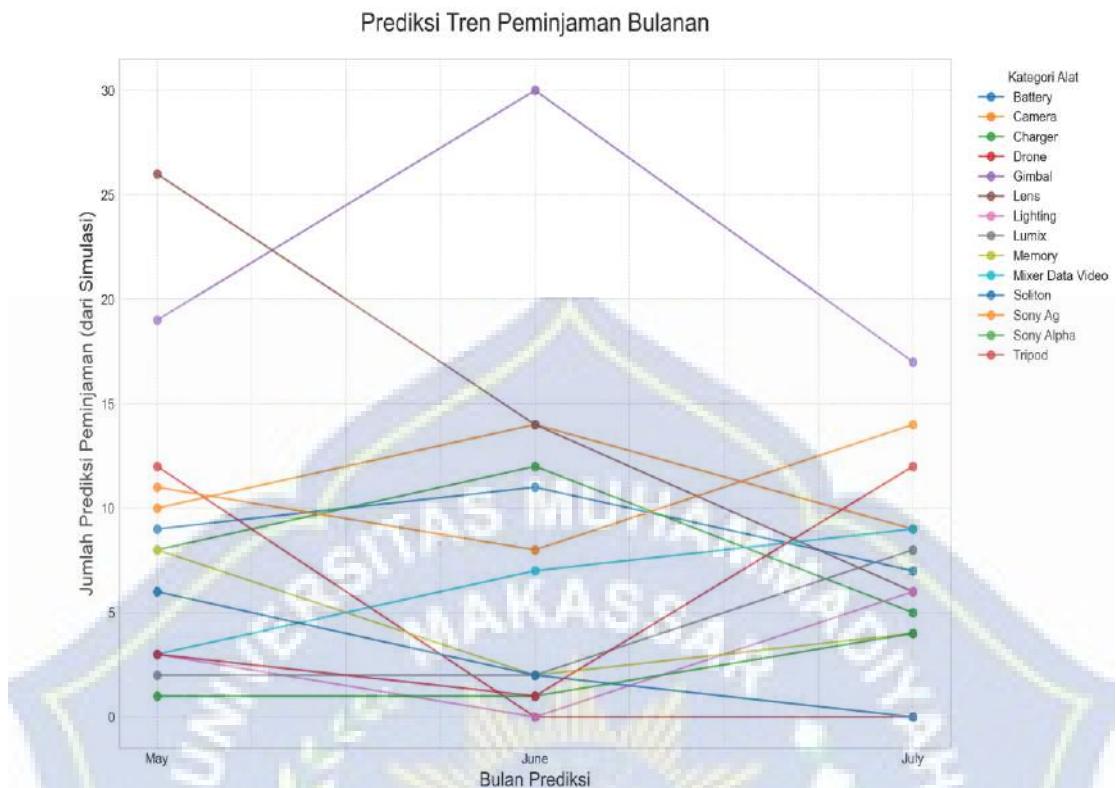
No.	Tanggal_Prediksi	Alat_Prediksi_Simplified
1	2025-05-01	Sony Ag
2	2025-05-01	Lens
3	2025-05-01	Charger
4	2025-05-01	Drone
5	2025-05-01	Camera

No.	Tanggal_Prediksi	Alat_Prediksi_Simplified
6	2025-05-01	Drone
7	2025-05-01	Sony Ag
8	2025-05-01	Lens
9	2025-05-01	Lens
10	2025-05-02	Lens
...
326	2025-07-31	Gimbal

Berdasarkan Tabel tersebut, dijelaskan bahwa model KNN yang digunakan tidak memprediksi tanggal peminjaman maupun jumlah peminjaman secara langsung. Tanggal peminjaman ditentukan melalui iterasi pada rentang waktu simulasi berdasarkan data historis. Setiap hari aktif dalam simulasi, program menjalankan 10 skenario prediksi jenis barang secara interaktif. Dari hasil tersebut, hanya prediksi dengan tingkat kepercayaan di atas 99% yang dipilih sebagai output yang valid. Selain itu, alat prediksi spesifik yang muncul merupakan pilihan acak dari daftar nama asli dalam kategori yang diprediksi, sehingga memberikan variasi yang lebih realistik pada hasil akhir. Sedangkan, kategori alat yang diprediksi oleh model KNN merupakan output utama yang menjadi fokus dalam analisis. Berdasarkan tabel hasil prediksi, analisis ini mengonfirmasi bahwa simulasi mampu menghasilkan prediksi harian yang spesifik dan dapat dijadikan acuan untuk tindakan lebih lanjut, dengan penyajian kategori alat yang diprediksi secara jelas dan terstruktur.

2. Analisis Tren Peminjaman Agregat Bulanan

Grafik ini memvisualisasikan proyeksi permintaan bulanan untuk setiap kategori alat, berdasarkan hasil simulasi yang telah difilter untuk hanya menyertakan prediksi dengan kepercayaan model. Analisis grafik ini, jika dihubungkan dengan hasil evaluasi model, memberikan beberapa wawasan kunci



Gambar 6 Grafik *time series* 3 bulan ke depan

Gambar 4.2 Grafik *time series* 3 bulan ke depan, tren permintaan bulanan yang berguna untuk perencanaan inventaris jangka menengah. Pada grafik tersebut, sumbu-X merepresentasikan bulan Mei, Juni, dan Juli dalam periode simulasi, sedangkan sumbu-Y menunjukkan jumlah total prediksi peminjaman yang dihasilkan untuk masing-masing bulan. Setiap garis berwarna pada grafik mewakili satu kategori alat yang berbeda. Dari grafik terlihat bahwa item Gimbal (berwarna ungu) dan Lens (berwarna coklat) mendominasi dengan volume prediksi tertinggi. Menariknya, meskipun kedua item ini memiliki performa F1-Score yang moderat (masing-masing 0,67 dan 0,73), pola peminjaman temporal mereka sangat kuat sehingga sering memicu prediksi dengan tingkat kepercayaan yang sangat tinggi. Sementara itu, item Camera (oranye) dan Battery (biru), yang memiliki F1-Score tertinggi (0,97 dan 1,00), menunjukkan tren permintaan yang lebih stabil dan moderat. Hal ini mencerminkan keandalan model dalam memprediksi aset-aset penting tersebut, dengan pola yang lebih tersebar namun dapat dikenali secara pasti. Di sisi lain, beberapa item seperti Tripod (merah) menunjukkan volatilitas tinggi

dalam permintaan, sementara *Lighting* (pink) dan *Drone* (merah marun) memiliki volume prediksi yang rendah. Kondisi ini konsisten dengan kinerja model yang moderat hingga rendah untuk item-item tersebut, karena pola peminjamannya lebih sulit diprediksi secara konsisten. Selain itu, item *Mixer Data Video* (kuning kehijauan) sama sekali tidak muncul dalam prediksi, yang secara visual mengonfirmasi skor F1 sebesar 0,00 yang tercantum dalam laporan klasifikasi. Secara keseluruhan, grafik ini tidak hanya memproyeksikan permintaan, tetapi juga secara visual menggambarkan kekuatan dan kelemahan model KNN. Grafik tersebut berhasil menyoroti alat dengan pola temporal yang kuat seperti *Gimbal* dan *Lens*, serta alat dengan prediksi yang sangat andal seperti *Camera* dan *Battery*, sehingga memberikan wawasan penting untuk perencanaan inventaris yang lebih efektif.

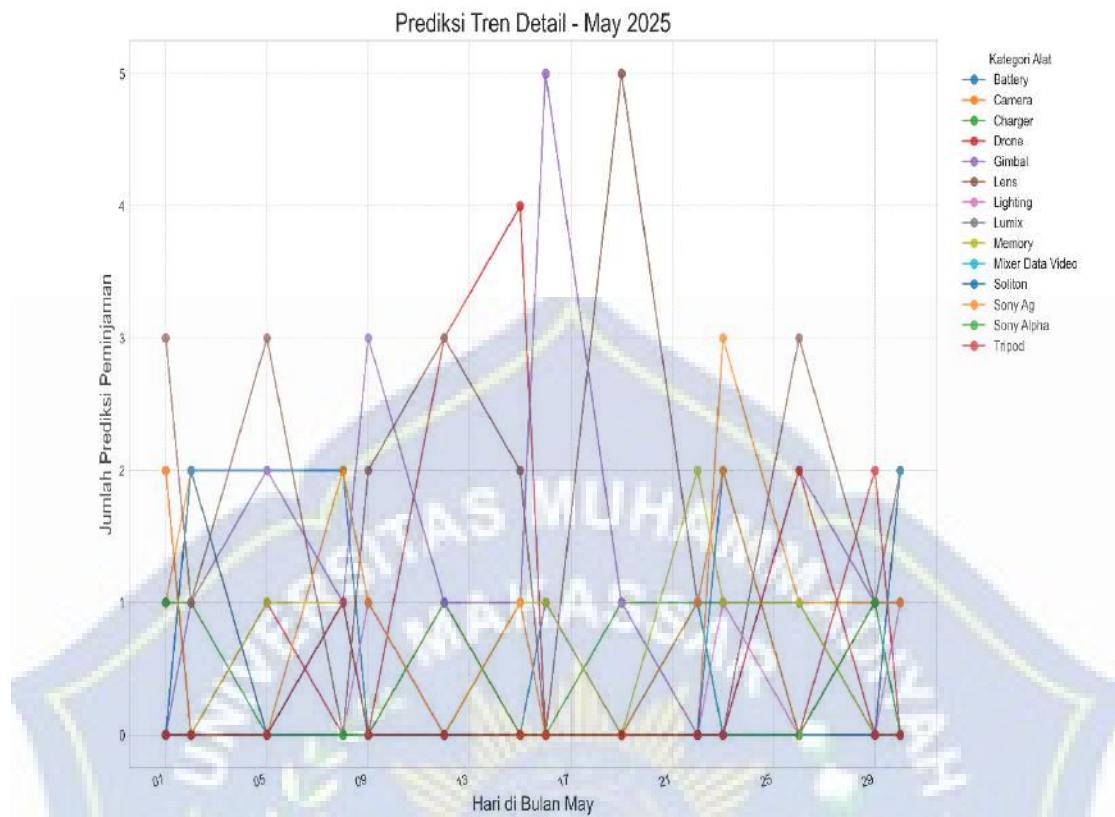
3. Analisis Fluktuasi Peminjaman Harian (Per Bulan)

Untuk mendapatkan pemahaman yang lebih operasional (mikro), data prediksi dipecah menjadi grafik harian untuk setiap bulan. Analisis ini berguna untuk melihat pola mingguan atau harian dan mengidentifikasi tanggal-tanggal spesifik dengan lonjakan permintaan.

a. Detail Prediksi Peminjaman - Mei 2025

Grafik ini menyajikan analisis mikro terhadap proyeksi permintaan harian selama bulan Mei 2025. Visualisasi ini merupakan agregat dari hasil simulasi probabilistik, di mana setiap titik data merepresentasikan jumlah kejadian prediksi. Dengan pendekatan ini, dapat terlihat dinamika fluktuasi permintaan harian untuk setiap kategori alat secara lebih rinci.

Pola yang ditampilkan membantu mengidentifikasi hari-hari dengan intensitas tinggi peminjaman serta alat yang cenderung lebih sering dipinjam dibandingkan lainnya. Informasi ini penting untuk mendukung perencanaan operasional, seperti pengaturan jadwal peminjaman, prioritas perawatan alat, dan strategi manajemen stok agar tidak terjadi kekurangan ketika permintaan mencapai puncaknya.



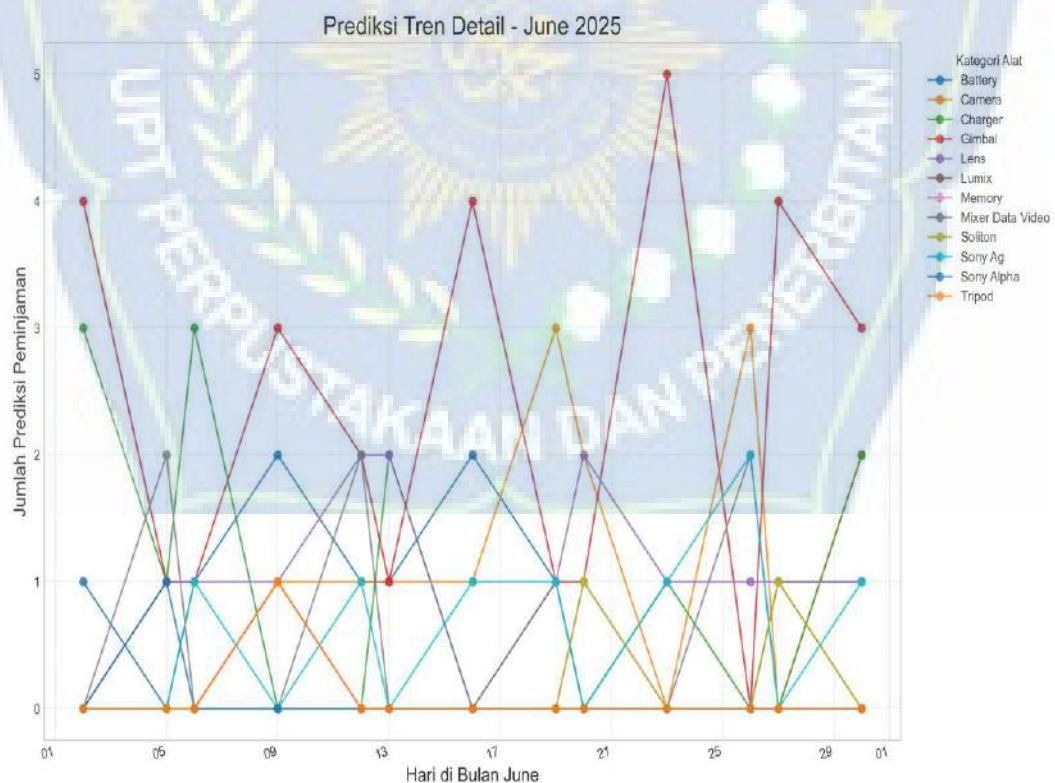
Gambar 7 Detail Prediksi Peminjaman bulan Mei

Analisis permintaan harian dan mingguan selama bulan Mei memperlihatkan pola yang jelas dan bervariasi antar kategori alat. Pada grafik, sumbu-X merepresentasikan setiap hari di bulan Mei 2025, sementara sumbu-Y menunjukkan jumlah prediksi peminjaman untuk hari tersebut. Setiap garis berwarna mewakili satu kategori alat. Terlihat bahwa Gimbal (ungu) dan Lens (coklat) mendominasi dengan puncak permintaan yang sangat tinggi; Gimbal mencapai puncak tertinggi dengan lima kejadian prediksi pada tanggal 17 Mei, sedangkan Lens juga mencapai lima kejadian pada tanggal 21 Mei. Meskipun F1-Score keduanya tergolong moderat, dominasi ini menandakan adanya sinyal temporal yang kuat yang berhasil diekstraksi oleh model. Selain itu, pola permintaan mingguan yang konsisten, terutama pada hari kerja seperti tanggal 5, 9, 13, 17, dan 21, menunjukkan korelasi yang erat antara permintaan aset dan siklus kerja mingguan. Aset Drone (merah) menunjukkan aktivitas signifikan di awal bulan, khususnya pada tanggal 1, 5, dan 9, sebelum aktivitasnya menurun drastis, yang mungkin mengindikasikan

kebutuhan proyek khusus di periode tersebut. Sementara itu, aset dengan performa model tinggi seperti Camera (orange) dan Battery (biru tua) menunjukkan pola permintaan yang lebih tersebar dan volume kejadian yang lebih rendah per hari, mencerminkan kebutuhan reguler yang tidak terkonsentrasi secara temporal seperti Gimbal atau Lens. Secara keseluruhan, analisis granula ini menegaskan bahwa Gimbal dan Lens merupakan aset dengan potensi permintaan tertinggi dan pola yang paling terstruktur, sementara pola mingguan yang teridentifikasi memberikan wawasan penting untuk perencanaan alokasi sumber daya harian. Variasi dinamika permintaan antar item, seperti aktivitas awal bulan pada Drone, memperlihatkan kemampuan model dalam menangkap pola-pola kompleks yang melampaui tren umum.

b. Detail Prediksi Peminjaman - Juni 2025

Grafik ini menyajikan analisis mikro terhadap prediksi permintaan harian selama bulan Juni 2025. Visualisasi ini merupakan agregat dari hasil simulasi probabilistik, di mana setiap titik data merepresentasikan jumlah kejadian prediksi.

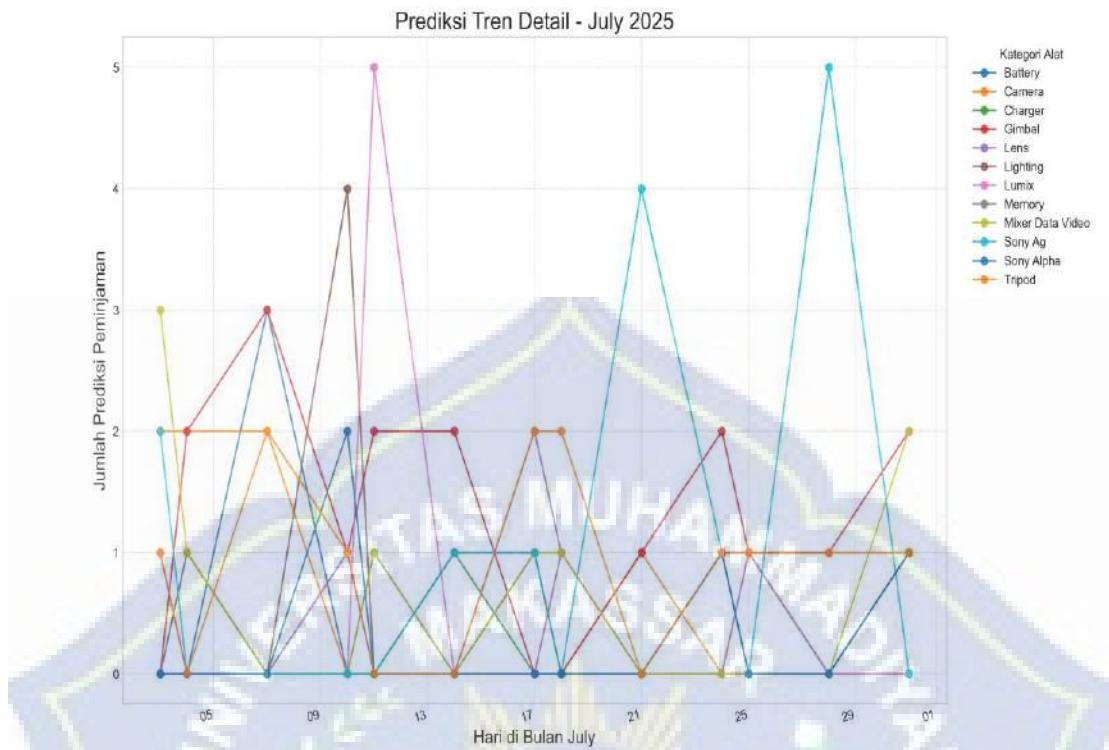


Gambar 8 Detail Prediksi Peminjaman bulan Juni

Analisis dinamika permintaan harian selama bulan Juni menunjukkan pola yang mirip dengan bulan Mei, di mana sumbu-X merepresentasikan hari-hari di bulan Juni dan sumbu-Y menunjukkan jumlah prediksi peminjaman pada hari tersebut. Aset Gimbal (merah) secara konsisten mendominasi dengan puncak permintaan tertinggi sepanjang bulan, dengan lonjakan signifikan yang muncul secara periodik sekitar tanggal 2, 9, 17, 23, dan 27. Pola ini semakin menguatkan adanya ritme mingguan yang kuat dalam kebutuhan operasional untuk aset tersebut. Meskipun kinerja model pada data uji untuk Gimbal hanya moderat dengan F1-Score 0,67, dominasi prediksi ini mengindikasikan bahwa sinyal temporal yang dipakai model sangat kuat untuk mengantisipasi permintaan Gimbal. Selain itu, aset pendukung seperti Charger (hijau) dan Camera (orange) menunjukkan pola permintaan yang lebih stabil dan konsisten. Charger dengan F1-Score 0,68 memiliki beberapa puncak permintaan menengah, sedangkan Camera dengan F1-Score 0,97 memperlihatkan aktivitas yang lebih tersebar sepanjang bulan, mencerminkan kebutuhan reguler keduanya sebagai item pendukung dan utama dalam produksi. Di sisi lain, aset seperti Lens (ungu) dan Battery (biru tua) menunjukkan aktivitas yang lebih sporadis dan volume permintaan yang lebih rendah dibandingkan bulan Mei, yang dapat diartikan sebagai pergeseran fokus kebutuhan produksi selama bulan Juni, dengan permintaan yang menjadi kurang terkonsentrasi secara temporal untuk kedua aset ini.

c. Detail Prediksi Peminjaman - Juli 2025

Grafik ini menyajikan analisis mikro terhadap proyeksi permintaan harian selama bulan Juli 2025. Visualisasi ini merupakan agregat dari hasil simulasi probabilistik, di mana setiap titik data merepresentasikan jumlah kejadian prediksi. Perlu ditekankan bahwa model KNN hanya memprediksi jenis aset, sementara tanggal berfungsi sebagai input simulasi dan jumlah adalah hasil agregasi kejadian.



Gambar 9 Detail Prediksi Peminjaman bulan Juli

Analisis perubahan tren permintaan harian di akhir periode simulasi, yaitu bulan Juli, memperlihatkan beberapa temuan penting. Pada grafik, sumbu-X merepresentasikan hari-hari di bulan Juli, sedangkan sumbu-Y menunjukkan jumlah prediksi peminjaman untuk setiap hari tersebut. Simulasi berhasil mengidentifikasi lonjakan permintaan yang signifikan untuk kategori Sony Ag dan Lumix pada tanggal-tanggal tertentu. Meskipun kedua kategori ini memiliki performa F1-Score yang moderat, tingginya frekuensi prediksi pada hari-hari spesifik menunjukkan adanya sinyal temporal yang kuat dalam data, yang mengindikasikan kebutuhan operasional yang sangat spesifik dan berpola. Sementara itu, aset dengan performa model terbaik seperti Battery dan Camera memperlihatkan distribusi prediksi yang lebih stabil dan konsisten sepanjang bulan, mengonfirmasi keandalan model dalam memprediksi permintaan untuk aset-aset vital dengan pola permintaan reguler yang tidak terkonsentrasi secara temporal. Selain itu, mayoritas puncak permintaan ditemukan pada hari kerja, memperkuat hipotesis adanya korelasi yang erat antara permintaan aset dengan siklus kerja mingguan. Model terbukti efektif memanfaatkan fitur temporal seperti hari ke dan

minggu ke untuk menangkap ritme operasional tersebut. Pergeseran dominasi permintaan dari Gimbal di bulan sebelumnya ke Sony Ag dan Lumix di bulan Juli menunjukkan sifat permintaan yang non-stasioner dan kemampuan model untuk beradaptasi serta mengidentifikasi perubahan tren berdasarkan input temporal yang berbeda. Secara keseluruhan, analisis granula bulan Juli berhasil mengidentifikasi hari-hari dengan probabilitas permintaan tinggi untuk aset-aset spesifik, memvalidasi pola periodik mingguan, dan menggambarkan dinamika tren permintaan. Karena visualisasi ini menggambarkan peta probabilitas kejadian dan bukan prediksi kuantitatif, hasilnya dapat dijadikan alat bantu keputusan yang bernilai dalam perencanaan alokasi sumber daya operasional jangka pendek.

H. Proyeksi Permintaan Model vs. Realitas Peminjaman

Setelah menganalisis hasil simulasi, langkah penting selanjutnya adalah membandingkan proyeksi permintaan yang dihasilkan oleh model dengan data peminjaman aktual pada periode yang sama (Mei - Juli). Analisis komparatif ini bertujuan untuk mengevaluasi validitas tren yang diidentifikasi oleh model dan memahami secara kritis mengapa terdapat perbedaan antara data proyeksi dan data Realita.

Tabel 13. peminjaman barang pada dunia nyata

NO	Nama Peminjam	Nama Alat	Tanggal Peminjaman	Nama Petugas	Tanggal pengembalian	Status Barang
1	Hakim	Sony Ag	02/05/2025	Rinus	06/05/2025	sudah dikembalikan
2	Hakim	Lensa Tele 400	02/05/2025	Rinus	06/05/2025	sudah dikembalikan
3	Hakim	charger 2 buah	02/05/2025	Rinus	06/05/2025	sudah dikembalikan
4	Hakim	drone mini 64	02/05/2025	Rinus	06/05/2025	sudah dikembalikan
5	Hakim	kamera sony	02/05/2025	Rinus	06/05/2025	sudah dikembalikan
.....
141	Hakim	memori	28/07/2025	Aswin	08/07/2025	sudah dikembalikan
142	Hakim	Charger	28/07/2025	Aswin	09/07/2025	sudah dikembalikan
143	Hakim	Charger	28/07/2025	Aswin	10/07/2025	sudah dikembalikan

Tabel 14. perbandingan hasil prediksi

Kategori Alat	Jumlah Prediksi (dari Simulasi)	Jumlah Peminjaman (Aktual)
Gimbal	66	25
Lens	46	21
Camera	33	20
Sony Ag	33	8
Battery	27	14
Charger	25	15
Tripod	16	8
Memory	14	7
Drone	12	5
Lumix	12	1
Mixer Data Video	19	10
Lighting	9	4
Soliton	8	2
Sony Alpha	6	2
Batarai	0	1
Total Keseluruhan	326	143

Analisis mendalam terhadap hasil model menunjukkan validitas yang kuat dalam mereplikasi tren popularitas aset. Model terbukti sangat andal dalam mengidentifikasi aset-aset kritis yang menjadi tulang punggung operasional, terlihat dari konsistensi tiga kategori teratas yaitu Gimbal, Lens, dan Camera. Selain itu, aset seperti *Charger*, *Battery*, dan *Tripod* yang secara konsisten berada di posisi tengah pada kedua daftar semakin memperkuat kemampuan model dalam memahami pola peminjaman secara umum. Namun, terdapat diskrepansi volume antara prediksi dan data aktual yang dapat dijelaskan oleh sifat simulasi itu sendiri. Model menjalankan 10 skenario peminjaman hipotetis untuk setiap hari aktif, sehingga total 326 prediksi yang dihasilkan bukanlah ramalan jumlah peminjaman sebenarnya, melainkan agregat dari skenario dengan tingkat kepercayaan tinggi di mana peminjaman diperkirakan terjadi. Filter ini memastikan bahwa hanya prediksi dengan tingkat kepercayaan di atas 99% yang dicatat, sehingga output lebih menggambarkan kumpulan skenario paling mungkin dari simulasi. Temuan spesifik mengungkap bahwa model memproyeksikan ‘Sony Ag’ sebanyak 33 kali, jauh lebih banyak dibanding Realita yang hanya 8, yang mengindikasikan bahwa berdasarkan fitur yang ada, model menganggap ‘Sony Ag’ sebagai pilihan yang logis, meskipun faktor-faktor lain seperti ketersediaan unit atau preferensi peminjam sesaat

mungkin memengaruhi hasil nyata. Selain itu, satu peminjaman aktual ‘Battery’ yang tidak terdeteksi dalam proyeksi menunjukkan bahwa pola peminjaman tersebut mungkin sangat tipikal dan tidak mencapai ambang batas kepercayaan dalam simulasi. Kesimpulannya, perbandingan antara data proyeksi dan data aktual tidak menunjukkan kegagalan sistem, melainkan menegaskan kekuatan model dalam mengidentifikasi aset krusial dan memeringkat potensi permintaan secara akurat. Tujuan utama model bukan untuk meramalkan jumlah transaksi secara tepat, melainkan untuk menyediakan daftar pantauan dinamis yang membantu manajemen inventaris memfokuskan perhatian dan sumber daya pada aset-aset yang paling relevan dan berpotensi tinggi dibutuhkan.

I. Implikasi Manajerial dan Keterbatasan

Analisis kinerja model dapat diterjemahkan menjadi rekomendasi strategis untuk manajemen *inventaris*.

Tabel 15. Keterangan Kepercayaan

Tingkat Kinerja Model	Kategori Alat Contoh (Ilustratif)	Tingkat Kepercayaan	Rekomendasi Tindakan Konkret
Tinggi (F1-Score > 0.8)	Camera, Battery	Tinggi	Gunakan prediksi sebagai dasar utama untuk perencanaan stok dan alokasi.
Moderat (F1-Score 0.5 - 0.8)	Tripod, Memory, Lens	Sedang	Gunakan prediksi sebagai indikator awal untuk kewaspadaan.
Rendah (F1-Score < 0.5)	Gimbal, Sony Alpha	Sangat Rendah	Abaikan sepenuhnya hasil prediksi untuk item-item ini.

BAB V

PENUTUP

A. Kesimpulan

Berdasarkan hasil analisis dan evaluasi yang telah diuraikan, diperoleh beberapa kesimpulan utama yang secara langsung menjawab rumusan masalah penelitian

1. Penerapan Algoritma KNN Berhasil Dilakukan Melalui Alur Kerja yang Komprehensif. Penelitian ini berhasil merancang dan mengimplementasikan sebuah *pipeline machine learning* yang sistematis. Alur kerja ini terbukti efektif, mencakup tahapan krusial mulai dari *pra-pemrosesan* data, pencegahan kebocoran data, penanganan kelas tidak seimbang dengan *SMOTE*, hingga optimasi *hyperparameter* melalui *GridSearchCV* yang menghasilkan konfigurasi model optimal ($k=3$, *metric='euclidean'*, *weights='distance'*).
2. Tingkat Akurasi Model Solid Namun Kontekstual dan Tersegmentasi, model KNN mencapai tingkat akurasi keseluruhan yang solid sebesar 80.18%, secara signifikan melampaui kinerja model dasar (*baseline*). Namun, analisis mendalam menunjukkan bahwa performa model sangat kontekstual dan bergantung pada volume data historis. Model menunjukkan keandalan sangat tinggi ($F1\text{-Score} > 0.95$) pada aset vital seperti 'Camera' dan 'Battery', namun kinerjanya menurun pada aset dengan data terbatas. Hal ini menegaskan bahwa efektivitas model harus dievaluasi secara tersegmentasi per kategori aset, bukan hanya berdasarkan akurasi agregat.

B. Saran

Berdasarkan kesimpulan dan keterbatasan yang teridentifikasi, berikut adalah saran yang dapat dipertimbangkan untuk implementasi dan pengembangan selanjutnya

1. Pemanfaatan teknik *balancing* data selain SMOTE seperti ADASYN atau kombinasi undersampling dan *oversampling*, dapat dicoba lalu dibandingkan kinerjanya terhadap hasil model yang ada.

2. Dapat dieksplorasi penggunaan metode optimasi *hyperparameter* lain seperti *Randomized Search* atau *Bayesian Optimization*, dan hasilnya dibandingkan dengan *GridSearchCV* untuk menilai efisiensinya.



DAFTAR PUSTAKA

- Aggarwal, R., Sounderajah, V., Martin, G., Ting, D. S. W., Karthikesalingam, A., King, D., Ashrafian, H., & Darzi, A. (2021). Diagnostic accuracy of deep learning in medical imaging: a systematic review and meta-analysis. In *npj Digital Medicine* (Vol. 4, Issue 1). Nature Research. <https://doi.org/10.1038/s41746-021-00438-z>
- Ardhana, S. R., Widiharih, T., & Saputra, B. A. (2024). Klasifikasi Menggunakan Algoritma K-Nearest Neighbor pada Imbalance Class Data dengan SMOTE. (Studi Kasus: Nasabah Bank Perkreditan Rakyat “X”). *Indonesian Journal of Applied Statistics*, 6(2), 152. <https://doi.org/10.13057/ijas.v6i2.79389>
- Artanti, V., Faisal, M., Kurniawan, F., & Sains dan Teknologi, F. (n.d.). *Klasifikasi Cardiovascular Diseases Menggunakan Algoritma K-Nearest Neighbors (KNN) Classification of Cardiovascular Diseases using K-Nearest Neighbors (KNN) Algorithm* (Vol. 23, Issue 2).
- Butsianto, S., & Mayangwulan, N. T. (2020). Penerapan Data Mining Untuk Prediksi Penjualan Mobil Menggunakan Metode K-Means Clustering. *Jurnal Nasional Komputasi Dan Teknologi Informasi*, 3(3).
- Çetin, V., & Yıldız, O. (2022). A comprehensive review on data preprocessing techniques in data analysis. *Pamukkale University Journal of Engineering Sciences*, 28(2), 299–312. <https://doi.org/10.5505/pajes.2021.62687>
- Christian, C., & Voutama, A. (2024). RANCANG BANGUN APLIKASI SISTEM INFORMASI INVENTARIS BERBASIS WEBSITE. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(2). <https://doi.org/10.23960/jitet.v12i2.4259>
- Dewi, S. P., Nurwati, N., & Rahayu, E. (2022). Penerapan Data Mining Untuk Prediksi Penjualan Produk Terlaris Menggunakan Metode K-Nearest Neighbor. *Building of Informatics, Technology and Science (BITS)*, 3(4), 639–648. <https://doi.org/10.47065/bits.v3i4.1408>
- Dwi Astuti, F., & Nova Lenti, F. (2021). *Implementasi SMOTE untuk mengatasi Imbalance Class pada Klasifikasi Car Evolution menggunakan K-NN*.

- Fadillah Hermawan, F., & Yamasari, Y. (2022). Implementasi K-Nearest Neighbor dengan Pemilihan Fitur pada Aplikasi Prediksi Kelayakan Pengajuan Pinjaman. *Journal of Informatics and Computer Science*, 03.
- Farooq, A., Abbey, A. B. N., & Onukwulu, E. C. (2024). Inventory Optimization and Sustainability in Retail: A Conceptual Approach to Data-Driven Resource Management. *International Journal of Multidisciplinary Research and Growth Evaluation*, 5(6), 1356–1363.
<https://doi.org/10.54660/IJMRGE.2024.5.6.1356-1363>
- Halder, R. K., Uddin, M. N., Uddin, M. A., Aryal, S., & Khraisat, A. (2024). Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications. *Journal of Big Data*, 11(1).
<https://doi.org/10.1186/s40537-024-00973-y>
- Hasanah, F., Suprapti, T., Rahaningsih, N., & Ali, I. (2022). Implementasi Algoritma K-Nearest Neighbor dalam Menentukan Buku Berdasarkan Peminatan. *Jurnal Accounting Information System (AIMS*, 5(1), 102–111.
<https://doi.org/10.32627>
- Heldi Hastriyandi, S. W. S. (2023). *SISTEM INFORMASI PENGELOLAAN ASET BARANG DAN PEMINJAMAN PERALATAN PADA LABORATORIUM DAN BENGKEL POLITEKNIK NEGERI SAMBAS BERBASIS WEB*.
- Hijrah & Maulidar. (2021). *Jurnal Teknologi dan Manajemen Informatika Analisis dan Perancangan Sistem Manajemen Inventaris Menggunakan Metode Fishbone Article Info ABSTRACT*. 7(2), 95–102.
<http://http://jurnal.unmer.ac.id/index.php/jtmi>
- Imron, M., & Kusumah, S. A. (2020). Application of Data Mining Classification Method for Student Graduation Prediction Using K-Nearest Neighbor (K-NN) Algorithm. *International Journal of Informatics and Information Systems*, 1(1), 1–8.
- Ismunandar, D., Firdaus, M. R., & Alkhaliifi, Y. (2024). PENERAPAN HYPERPARAMETER MACHINE LEARNING DALAM PREDIKSI GAGAL PINJAM. *INTI Nusa Mandiri*, 19(1), 62–70.
<https://doi.org/10.33480/inti.v19i1.5612>

- Jollyta, D., & Ramdhan, W. (2020). *Konsep Data Mining dan Penerapan*.
- Juniar, D., & Daniawan, B. (2024). Optimasi Sistem Informasi Pembelian, Persediaan, dan Penjualan Barang dengan Penerapan Metode Algoritma Apriori. *Jurnal Teknik Informatika Dan Sistem Informasi*, 10(1). <https://doi.org/10.28932/jutisi.v10i1.7647>
- Luki Karunia, R., & Malik Ibrahim Politeknik STIA LAN Jakarta, M. (2021). PELAKSANAAN INVENTARISASI ASET TETAP DI KEMENTERIAN KOORDINATOR BIDANG PEMBANGUNAN MANUSIA DAN KEBUDAYAAN. In *Journal of Business Administration Economic & Entrepreneurship* (Vol. 3, Issue 2).
- Mardiyyah, N. W., Rahaningsih, N., & Ali, I. (2024). PENERAPAN DATA MINING MENGGUNAKAN ALGORITMA K-NEAREST NEIGHBOR PADA PREDIKSI PEMBERIAN KREDIT DI SEKTOR FINANSIAL. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 8, Issue 2). www.kaggle.com
- Papakyriakou, D., & Barbounakis, I. S. (2022). Data Mining Methods: A Review. *International Journal of Computer Applications*, 183(48), 5–19. <https://doi.org/10.5120/ijca2022921884>
- Pranoto, A. O., & Sediyono, E. (2021). Perancangan Sistem Informasi Inventaris Barang Berbasis Web. *Jurnal Teknik Informatika Dan Sistem Informasi*, 7(2). <https://doi.org/10.28932/jutisi.v7i2.3597>
- Rahma, S. M., Oktadini, N. R., & Indah, D. R. (2024). PENERAPAN DATA MINING UNTUK PREDIKSI PENJUALAN OBAT MENGGUNAKAN METODE K-NEAREST NEIGHBOR. *JOISIE (Journal Of Information Systems And Informatics Engineering)*, 8(2), 259. <https://doi.org/10.35145/joisie.v8i2.4725>
- Rizkia Malik, R., Rizal, E., & Rodiah, S. (2023). *PENGELOLAAN ASET DIGITAL DI LIBRARY SCTV*. 2(5). <https://doi.org/10.56127/jukim.v2i05>
- Salih, A. A., & Abdulazeez, A. M. (2021). Evaluation of Classification Algorithms for Intrusion Detection System: A Review. *Journal of Soft Computing and Data Mining*, 2(1), 31–40. <https://doi.org/10.30880/jscdm.2021.02.01.004>

- Siswo Adiguno & Yohanni Syahra & Milfa Yetri. (2022). *Prediksi Peningkatan Omset Penjualan Menggunakan Metode Regresi Linier Berganda*.
- Syahril Dwi Prasetyo, Shofa Shofiah Hilabi, & Fitri Nurapriani. (2023). Analisis Sentimen Relokasi Ibukota Nusantara Menggunakan Algoritma Naïve Bayes dan KNN. *Jurnal KomtekInfo*, 1–7. <https://doi.org/10.35134/komtekinfo.v10i1.330>
- Tembusai, Z. R., Mawengkang, H., & Zarlis, M. (2021). K-Nearest Neighbor with K-Fold Cross Validation and Analytic Hierarchy Process on Data Classification. *International Journal of Advances in Data and Information Systems*, 2(1). <https://doi.org/10.25008/ijadis.v2i1.1204>
- Yang, J., Li, Y., Liu, Q., Li, L., Feng, A., Wang, T., Zheng, S., Xu, A., & Lyu, J. (2020). Brief introduction of medical database and data mining technology in big data era. In *Journal of Evidence-Based Medicine* (Vol. 13, Issue 1, pp. 57–69). Blackwell Publishing. <https://doi.org/10.1111/jebm.12373>
- Yenila, F., Marfalino, H., & Defit, S. (2023). Model Analisis Machine Learning dengan Pendekatan Deep Learning dalam Penentuan Kolektabilitas. *JST (Jurnal Sains Dan Teknologi)*, 12(2). <https://doi.org/10.23887/jstundiksha.v12i2.54035>
- Zhang, S. (2022). Challenges in KNN Classification. *IEEE Transactions on Knowledge and Data Engineering*, 34(10), 4663–4675. <https://doi.org/10.1109/TKDE.2021.3049250>

LAMPIRAN

Lampiran 1 data mentah

1	Nama Per Nama Alat	Tanggal Peminjaman	Nama Petugas	Tanggal Pengembalian	status pengembalian
2	Rinus memori 2 buah 256 gb	03/05/2023	Rinus	06/05/2023	sudah dikembalikan
3	Rinus Tuki	03/05/2023	Rinus	06/05/2023	sudah dikembalikan
4	Rinus Memori 2buah 256 tvri 3	03/05/2023	Rinus	06/05/2023	sudah dikembalikan
5	Rinus memori 256 tuki 1	03/05/2023	Rinus	06/05/2023	sudah dikembalikan
6	Rinus kamera sony A9	03/05/2023	Rinus	06/05/2023	sudah dikembalikan
7	Rinus lensa standar	03/05/2023	Rinus	15/05/2023	sudah dikembalikan
8	Rial lensa tele	11/05/2023	Rinus	15/05/2023	sudah dikembalikan
9	Rial lensa milda	11/05/2023	Rinus	15/05/2023	sudah dikembalikan
10	Rial tripot	11/05/2023	Rinus	15/05/2023	sudah dikembalikan
11	Rial batrai 3 buah	11/05/2023	Rinus	15/05/2023	sudah dikembalikan
66	Hakim Kamera sony alpa 94	02/06/2023	Hakim	07/06/2023	sudah dikembalikan
67	Hakim alpa 9	02/06/2023	Hakim	07/06/2023	sudah dikembalikan
68	Hakim memori 256 2 buah	02/06/2023	Hakim	07/06/2023	sudah dikembalikan
69	Ilham kamera sony A9 1 buah	17/06/2023	RINUS	23/06/2023	sudah dikembalikan
70	Ilham lensa widg 12/24 1 buah	17/06/2023	Rinus	23/06/2023	sudah dikembalikan
71	Ilham lensa tele 100/400 7 bual	17/06/2023	Rinus	23/06/2023	sudah dikembalikan
72	Ilham Batrai 2 buah	17/06/2023	Rinus	23/06/2023	sudah dikembalikan
73	Ilham carger 1 buah	17/06/2023	Rinus	23/06/2023	sudah dikembalikan
74	Ilham memori 256 GB	17/06/2023	Rinus	23/06/2023	sudah dikembalikan
75	Bu yola Tripot libek 1 buah	23/06/2023	Rinus	03/07/2023	sudah dikembalikan
76	Bu yola camera sony A9	23/06/2023	Rinus	03/07/2023	sudah dikembalikan
120	Amril lampu body	11/07/2023	Rinus	15/07/2023	sudah dikembalikan
121	Amril lampu gvm	11/07/2023	Rinus	15/07/2023	sudah dikembalikan
122	Amril lampu gvm	11/07/2023	Rinus	15/07/2023	sudah dikembalikan
123	Hakim kamera sony A9 full set	18/07/2023	Rinus	15/07/2023	sudah dikembalikan
124	Hakim kamera sony A9 2 full set	18/07/2023	Rinus	15/07/2023	sudah dikembalikan
125	Hakim memori 256 GB	18/07/2023	Rinus	15/07/2023	sudah dikembalikan
126	Hakim memori 256 GB	18/07/2023	Rinus	15/07/2023	sudah dikembalikan
127	Hakim Gimbal	18/07/2023	Rinus	15/07/2023	sudah dikembalikan
128	Rinus Kamera Lumix	18/07/2023	Rinus	22/07/2023	sudah dikembalikan
129	Rinus Kamera Lumix	18/07/2023	Rinus	22/07/2023	sudah dikembalikan
130	Rinus Batrai	18/07/2023	Rinus	22/07/2023	sudah dikembalikan
204	Rinus Tripod	07/08/2023	Rinus	09/08/2023	sudah dikembalikan
205	Rinus Tripod	07/08/2023	Rinus	09/08/2023	sudah dikembalikan
206	Amril Lampu GVM	10/08/2023	Rinus	14/08/2023	sudah dikembalikan
207	Amril Tripod	10/08/2023	Rinus	14/08/2023	sudah dikembalikan
208	Amril Tripod	10/08/2023	Rinus	14/08/2023	sudah dikembalikan
209	Amril Lampu Godox	10/08/2023	Rinus	14/08/2023	sudah dikembalikan
210	Amril Lampu Godox	10/08/2023	Rinus	14/08/2023	sudah dikembalikan
211	Kun Cam Sony Ag	11/08/2023	Aswin	14/08/2023	sudah dikembalikan
212	Kun Memory 256 GB 11/08/20.	11/08/2023	Aswin	14/08/2023	sudah dikembalikan
213	Kun Lensa Tele	11/08/2023	Aswin	14/08/2023	sudah dikembalikan
214	Kun Baterai	11/08/2023	Aswin	14/08/2023	sudah dikembalikan
230	Rinus Camera Sony Ag	02/09/2023	Rinus	28/08/2023	sudah dikembalikan
231	Rinus Baterai	02/09/2023	Rinus	28/08/2023	sudah dikembalikan
232	Rinus Baterai	02/09/2023	Rinus	28/08/2023	sudah dikembalikan
233	Rinus Baterai	02/09/2023	Rinus	28/08/2023	sudah dikembalikan
234	Rinus Baterai	02/09/2023	Rinus	28/08/2023	sudah dikembalikan
235	Rinus Gimbal Zhiyun	02/09/2023	Rinus	28/08/2023	sudah dikembalikan
236	Rinus Lensa Standar & Wide	02/09/2023	Rinus	28/08/2023	sudah dikembalikan
237	Rinus Tripod Libec02/09/2023	03/09/2023	Rinus	29/08/2023	sudah dikembalikan
238	Rinus Tripod Libec	02/09/2023	Rinus	28/08/2023	sudah dikembalikan
239	Rinus Memory 256 GB No 4&5	02/09/2023	Rinus	28/08/2023	sudah dikembalikan
240	Firman Camera Sony Ag	06/09/2023	Rinus	17/09/2023	sudah dikembalikan

286	Kun (Aji)	Sony Ag	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
287	Kun (Aji)	Sony Ag	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
288	Kun (Aji)	Tripod Libec	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
289	Kun (Aji)	Tripod Libec	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
290	Kun (Aji)	Lensa Wide & Standar	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
291	Kun (Aji)	Charger	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
292	Kun (Aji)	Charger	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
293	Kun (Aji)	Baterai	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
294	Kun (Aji)	Baterai	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
295	Kun (Aji)	Baterai	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
296	Kun (Aji)	Baterai	09/10/2023	Aswin	27/09/2023	sudah dikembalikan
371	Amril	Lampu Godox	02/11/2023	Rinus	02/11/2023	sudah dikembalikan
372	Amril	Lampu Godox (Portable	02/11/2023	Aswin	02/11/2023	sudah dikembalikan
373	Amril	Lampu Godox (Portable	02/11/2023	Aswin	02/11/2023	sudah dikembalikan
374	Halam	Lumix	07/11/2023	Halam	12/11/2023	sudah dikembalikan
375	Halam	Baterai	07/11/2023	Halam	12/11/2023	sudah dikembalikan
376	Halam	Baterai	07/11/2023	Halam	12/11/2023	sudah dikembalikan
377	Halam	Baterai	07/11/2023	Halam	12/11/2023	sudah dikembalikan
378	Halam	Sony Alpha	07/11/2023	Halam	12/11/2023	sudah dikembalikan
379	Halam	Baterai	07/11/2023	Halam	12/11/2023	sudah dikembalikan
380	Halam	Baterai	07/11/2023	Halam	12/11/2023	sudah dikembalikan
381	Rial	Lumix	13/11/2023	Rinus	19/11/2023	sudah dikembalikan
404	Pak Kun	Camera XDCam	01/12/2023	Rinus	07/12/2023	sudah dikembalikan
405	Pak Kun	Baterai	01/12/2023	Rinus	07/12/2023	sudah dikembalikan
406	Pak Kun	Charger	01/12/2023	Rinus	07/12/2023	sudah dikembalikan
407	Pak Kun	Memory 256 GB	01/12/2023	Rinus	07/12/2023	sudah dikembalikan
408	Ilham	Camera Sony Ag	03/12/2023	Rinus	07/12/2023	sudah dikembalikan
409	Ilham	Charger	03/12/2023	Rinus	07/12/2023	sudah dikembalikan
410	Ilham	Baterai	03/12/2023	Rinus	07/12/2023	sudah dikembalikan
411	Ilham	Baterai	03/12/2023	Rinus	07/12/2023	sudah dikembalikan
412	Ilham	Memory 256GB	03/12/2023	Rinus	07/12/2023	sudah dikembalikan
413	Ilham	Gimbal Zhiyun	03/12/2023	Rinus	07/12/2023	sudah dikembalikan
414	Ilham	tripod	12/03/2023	Rinus	04/12/2023	sudah dikembalikan
446	Eko	Camera Sony Ag	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
447	Eko	Baterai	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
448	Eko	Charger	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
449	Eko	Tas Camera	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
450	Rinus	Camera Sony Ag	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
451	Rinus	Baterai	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
452	Rinus	Baterai	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
453	Rinus	Charger	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
454	Rinus	Memory 256GB	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
455	Rinus	Lensa Wide & Tele 70/200	22/01/2024	Aswin	22/01/2024	sudah dikembalikan
456	Rinus	Gimbal Zhiyun	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
457	Rinus	Tripod	18/01/2024	Aswin	22/01/2024	sudah dikembalikan
490	Hamdani	Sony Ag	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
491	Hamdani	Charger	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
492	Hamdani	Charger	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
493	Hamdani	Baterai	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
494	Hamdani	Baterai	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
495	Hamdani	Lensa	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
496	Hamdani	Lensa	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
497	Hamdani	Lensa	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
498	Hamdani	Lensa	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
499	Hamdani	Tripod	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
500	Hamdani	Memory 256GB	11/02/2024	Aswin	13/02/2024	sudah dikembalikan
567	Pak Firma	Mixer Data Video	01/03/2024	Rinus	02/03/2024	sudah dikembalikan
568	Pak Firma	Camera XDCam	01/03/2024	Rinus	02/03/2024	sudah dikembalikan
569	Pak Firma	Camera XDCam	01/03/2024	Rinus	02/03/2024	sudah dikembalikan
570	Pak Firma	Camera XDCam	01/03/2024	Rinus	02/03/2024	sudah dikembalikan
571	Pak Firma	Tripod	01/03/2024	Rinus	02/03/2024	sudah dikembalikan
572	Pak Firma	Tripod	01/03/2024	Rinus	02/03/2024	sudah dikembalikan
573	Pak Firma	Tripod	01/03/2024	Rinus	02/03/2024	sudah dikembalikan
574	Pak Firma	Recording Black Magick	01/03/2024	Rinus	02/03/2024	sudah dikembalikan
575	Pak Firma	Memory 256GB	01/03/2024	Rinus	02/03/2024	sudah dikembalikan
576	Amril	Sony Ag	03/04/2024	Hakim	06/03/2024	sudah dikembalikan

576	Amril	Sony Ag		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
577	Amril	Sony Ag		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
578	Amril	Baterai		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
579	Amril	Baterai		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
580	Amril	Baterai		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
581	Amril	batrai		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
582	Amril	Charger		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
583	Amril	Charger		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
584	Amril	Tripod		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
585	Amril	Tripod		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
586	Amril	Lampu Godox portable		03/04/2024	Hakim		06/03/2024	sudah dikembalikan
678	Aji Ilham	Camera Sony Ag		07/05/2024	Aswin/Rinus		09/05/2024	sudah dikembalikan
679	Aji Ilham	Tripod Libec		07/05/2024	Aswin/Rinus		09/05/2024	sudah dikembalikan
680	Aji Ilham	Baterai Camera		07/05/2024	Aswin/Rinus		09/05/2024	sudah dikembalikan
681	Aji Ilham	Baterai Camera		07/05/2024	Aswin/Rinus		09/05/2024	sudah dikembalikan
682	Aji Ilham	Lensa Tele & Wide		07/05/2024	Aswin/Rinus		09/05/2024	sudah dikembalikan
683	Aji Ilham	Memory 256GB		07/05/2024	Aswin/Rinus		09/05/2024	sudah dikembalikan
684	Aji Ilham	Lighting Portabel		07/05/2024	Rinus		09/05/2024	sudah dikembalikan
685	Aji Ilham	Lighting Portabel		07/05/2024	Rinus		09/05/2024	sudah dikembalikan
686	Aji Ilham	Stand Lighting		07/05/2024	Rinus		09/05/2024	sudah dikembalikan
687	Aji Ilham	Stand Lighting		07/05/2024	Rinus		09/05/2024	sudah dikembalikan
688	Aji Ilham	Drone		07/05/2024	Rinus		09/05/2024	sudah dikembalikan
734	Pak Firma	Memory 256GB		06/06/2024	Rinus		10/06/2024	sudah dikembalikan
735	Pak Firma	Camera		06/06/2024	Aswin		10/06/2024	sudah dikembalikan
736	Pak Firma	Camera		06/06/2024	Aswin		10/06/2024	sudah dikembalikan
737	Kak Eko	Camera		16/06/2024	Aswin		20/06/2024	sudah dikembalikan
738	Kak Eko	Tripod		16/06/2024	Aswin		20/06/2024	sudah dikembalikan
739	Kak Eko	Tripod		16/06/2024	Aswin		20/06/2024	sudah dikembalikan
740	Kak Eko	Tripod		16/06/2024	Aswin		20/06/2024	sudah dikembalikan
741	Kak Eko	Charger		16/06/2024	Aswin		20/06/2024	sudah dikembalikan
742	Kak Eko	Charger		16/06/2024	Aswin		20/06/2024	sudah dikembalikan
743	Kak Eko	Charger		16/06/2024	Aswin		20/06/2024	sudah dikembalikan
744	Kak Eko	Baterai		16/06/2024	Aswin		20/06/2024	sudah dikembalikan
748	Pak Firma	Sony Ag		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
749	Pak Firma	Baterai Sony		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
750	Pak Firma	Baterai Sony		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
751	Pak Firma	Baterai Sony		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
752	Pak Firma	Baterai Sony		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
753	Pak Firma	Memory 256GB		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
754	Pak Firma	Memory 256GB		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
755	Pak Firma	Gimbal Ziyun		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
756	Pak Firma	Tripod		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
757	Pak Firma	Lensa Wide		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
758	Pak Firma	Lensa Tele 400		04/07/2024	Rinus		07/07/2024	sudah dikembalikan
817	Hakim	Baterai		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
818	Hakim	Baterai		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
819	Hakim	Baterai		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
820	Hakim	Baterai		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
821	Hakim	Baterai		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
822	Hakim	Baterai		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
823	Hakim	Charger		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
824	Hakim	Charger		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
825	Hakim	Tripod		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
826	Hakim	Memory 256GB		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
827	Hakim	Memory 256GB		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
828	Hakim	Gimbal Dji		03/08/2024	Rinus		04/08/2024	sudah dikembalikan
873	Rinus	Memory 256GB		03/09/2024	Aswin		04/09/2024	sudah dikembalikan
874	Rinus	Camera XDCam		03/09/2024	Aswin		04/09/2024	sudah dikembalikan
875	Rinus	Camera Sony		03/09/2024	Aswin		04/09/2024	sudah dikembalikan
876	Rinus	Baterai		03/09/2024	Aswin		04/09/2024	sudah dikembalikan
877	Rinus	Baterai		03/09/2024	Aswin		04/09/2024	sudah dikembalikan
878	Rinus	Charger		03/09/2024	Aswin		04/09/2024	sudah dikembalikan
879	Hakim	Camera Lumix		10/09/2024	Rinus		14/09/2024	sudah dikembalikan
880	Hakim	Camera Lumix		10/09/2024	Rinus		14/09/2024	sudah dikembalikan
881	Hakim	Baterai		10/09/2024	Rinus		14/09/2024	sudah dikembalikan
882	Hakim	Baterai		10/09/2024	Rinus		14/09/2024	sudah dikembalikan
883	Hakim	Baterai		10/09/2024	Rinus		14/09/2024	sudah dikembalikan

921	Eko	Camera Sony	03/10/2024	Rinus	05/10/2024	sudah dikembalikan
922	Eko	Camera Sony	03/10/2024	Rinus	05/10/2024	sudah dikembalikan
923	Eko	Camera Sony	03/10/2024	Rinus	05/10/2024	sudah dikembalikan
924	Eko	Camera Sony	03/10/2024	Rinus	05/10/2024	sudah dikembalikan
925	Eko	Charger	03/10/2024	Rinus	05/10/2024	sudah dikembalikan
926	Eko	Tripod	03/10/2024	Rinus	05/10/2024	sudah dikembalikan
927	Eko	Baterai	03/10/2024	Rinus	05/10/2024	sudah dikembalikan
928	Armawi	Camera Sony Ag	06/10/2024	Rinus	13/10/2024	sudah dikembalikan
929	Armawi	Lensa Tele 200	06/10/2024	Rinus	13/10/2024	sudah dikembalikan
930	Armawi	Lensa Wide	06/10/2024	Rinus	13/10/2024	sudah dikembalikan
931	Armawi	Baterai	06/10/2024	Rinus	13/10/2024	sudah dikembalikan
1022	Hamdani	Camera Sony Ag	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1023	Hamdani	Camera Sony Ag	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1024	Hamdani	Memory	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1025	Hamdani	Memory	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1026	Hamdani	Baterai	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1027	Hamdani	Baterai	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1028	Hamdani	Baterai	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1029	Hamdani	Baterai	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1030	Hamdani	Lampu Cat	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1031	Hamdani	Tripod	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1032	Hamdani	Gimbal Ziyun	15/11/2024	Aswin	23/10/2024	sudah dikembalikan
1033	Hamdani	Gimbal Ziyun	02/12/2024	Rinus	06/12/2024	sudah dikembalikan
1065	Armawi	cas	02/12/2024	Rinus	06/12/2024	sudah dikembalikan
1066	Hakim	Memory	02/12/2024	Rinus	06/12/2024	sudah dikembalikan
1067	Hakim	Memory	02/12/2024	Rinus	06/12/2024	sudah dikembalikan
1068	Hakim	Memory	02/12/2024	Rinus	06/12/2024	sudah dikembalikan
1069	Hakim	Memory	02/12/2024	Rinus	06/12/2024	sudah dikembalikan
1070	Hakim	Camera Sony Ag	02/12/2024	Rinus	06/12/2024	sudah dikembalikan
1071	Hakim	Camera Sony Ag	02/12/2024	Rinus	06/12/2024	sudah dikembalikan
1072	Rinus	Baterai	16/12/2024	Rinus	06/12/2024	sudah dikembalikan
1073	Rinus	Baterai	16/12/2024	Rinus	26/12/2024	sudah dikembalikan
1101	Iccang	Charger	02/01/2025	Rinus	02/01/2025	sudah dikembalikan
1102	Iccang	Baterai	02/01/2025	Rinus	02/01/2025	sudah dikembalikan
1103	Iccang	Baterai	02/01/2025	Rinus	02/01/2025	sudah dikembalikan
1104	Iccang	Baterai	02/01/2025	Rinus	02/01/2025	sudah dikembalikan
1105	Hamdani	Camera Sony Ag	13/01/2025	Aswin	18/01/2025	sudah dikembalikan
1106	Hamdani	Camera Sony Ag2	13/01/2025	Aswin	18/01/2025	sudah dikembalikan
1107	Hamdani	Lensa Sony Wide	13/01/2025	Aswin	18/01/2025	sudah dikembalikan
1108	Hamdani	Lensa Sony tele	13/01/2025	Aswin	18/01/2025	sudah dikembalikan
1109	Hamdani	Lensa Sony Fix	13/01/2025	Aswin	18/01/2025	sudah dikembalikan
1110	Hamdani	Baterai	13/01/2025	Aswin	18/01/2025	sudah dikembalikan
1111	Hamdani	Baterai	13/01/2025	Aswin	18/01/2025	sudah dikembalikan
1131	FAJRUL	KAMERA LUMIX-1	02/02/2025	RINUS	09/02/2025	sudah dikembalikan
1132	FAJRUL	CHANGER=1	02/02/2025	RINUS	09/02/2025	sudah dikembalikan
1133	FAJRUL	BATERAN=3	02/02/2025	RINUS	09/02/2025	sudah dikembalikan
1134	FAJRUL	TRIPOD LIBEN=1	02/05/2025	RINUS	09/02/2025	sudah dikembalikan
1135	FAJRUL	MEMORI 256=1	02/02/2025	RINUS	09/02/2025	sudah dikembalikan
1136	FAJRUL	LIGHTING=1	02/02/2025	RINUS	09/02/2025	sudah dikembalikan
1137	FAJRUL	Memoriy tupi=3	02/02/2025	RINUS	09/02/2025	sudah dikembalikan
1138	FAJRUL	NEMORY TURI C1	02/02/2025	RINUS	09/02/2025	sudah dikembalikan
1139	Armawi	Done Movie Pro 2	21/02/2025	RINUS	24/02/2025	sudah dikembalikan
1140	Armawi	Memo G4 GB	21/02/2025	RINUS	24/02/2025	sudah dikembalikan
1141	SAHRIAL	KAMERA SONY A9	24/02/2025	RINUS	24/02/2025	sudah dikembalikan

1157	fajrul	XXD Lam 1 buah	03/03/2025	HAKiM	03/03/2025	sudah dikembalikan
1158	fajrul	batri 2 buah	03/03/2025	HAKiM	03/03/2025	sudah dikembalikan
1159	fajrul	ccharger 1 buah	03/03/2025	HAKiM	03/03/2025	sudah dikembalikan
1160	fajrul	Lighting	03/03/2025	HAKiM	03/03/2025	sudah dikembalikan
1161	fajrul	Tripod Libek 1 buah	03/03/2025	HAKiM	03/03/2025	sudah dikembalikan
1162	fajrul	Solitom	03/03/2025	HAKiM	03/03/2025	sudah dikembalikan
1163	wandi	Cam lumix2 buah	06/03/2025	Rinus	06/03/2025	sudah dikembalikan
1164	wandi	Batrei 6 buah	06/03/2025	Rinus	06/03/2025	sudah dikembalikan
1165	wandi	Charger 2 buah	06/03/2025	Rinus	06/03/2025	sudah dikembalikan
1166	wandi	Tripod 2 buah	06/03/2025	Rinus	06/03/2025	sudah dikembalikan
1167	wandi	Libek basar	06/03/2025	Rinus	06/03/2025	sudah dikembalikan
1203	Aji	soltion 1 set	24/04/2025	Aji	29/04/2025	sudah dikembalikan
1204	Aji	tripot libek	24/04/2025	Aji	29/04/2025	sudah dikembalikan
1205	Aji	xd canon	24/04/2025	Aji	29/04/2025	sudah dikembalikan
1206	Aji	batri 1 buah	24/04/2025	Aji	29/04/2025	sudah dikembalikan
1207	Aji	soltion 1 set	24/04/2025	Aji	29/04/2025	sudah dikembalikan
1208	Aji	tripod libel	24/04/2025	Aji	29/04/2025	sudah dikembalikan
1209	Aji	xd canon	24/04/2025	Aji	29/04/2025	sudah dikembalikan
1210	Aji	ligting 1 buah	24/04/2025	Aji	29/04/2025	sudah dikembalikan



Lampiran 2. Code program

```
import pandas as pd
import numpy as np
from sklearn.preprocessing import LabelEncoder, StandardScaler
from sklearn.model_selection import train_test_split, GridSearchCV, StratifiedKFold
from sklearn.neighbors import KNeighborsClassifier
from sklearn.metrics import accuracy_score, classification_report, confusion_matrix,
ConfusionMatrixDisplay
from imblearn.over_sampling import SMOTE
import matplotlib.pyplot as plt
import matplotlib.dates as mdates
import seaborn as sns
import pickle
import random
import os
import calendar
from typing import List, Dict, Tuple

class Konfigurasi:
    """Menampung semua konfigurasi untuk skrip."""
    FOLDER_DATA = "data"
    FOLDER_MODEL = "models"
    FOLDER_OUTPUT = "output"
    NAMA_FILE_DATA = "datarill.csv"

    # Nama Kolumn
    KOLOM_TANGGAL_PINJAM = "Tanggal Peminjaman"
    KOLOM_NAMA_ALAT = "Nama Alat"
    KOLOM_NAMA_PEMINJAM = "Nama Peminjam"
    KOLOM_NAMA_ALAT_SIMPLE = "Nama Alat Simplified"

    # Pengaturan Model & Fitur
    UKURAN_DATA_UJI = 0.2
    RANDOM_STATE = 42
    MIN_SAMPEL_PER_KELAS = 3
    JUMLAH_CV_SPLITS = 5

    # Pengaturan Simulasi
    TANGGAL_AWAL_SIMULASI = "2025-05-01"
    TANGGAL_AKHIR_SIMULASI = "2025-07-31"
    AMBANG_BATAS_TRANSAKSI = 0.15
    ITERASI_SIMULASI_PER_HARI = 10
    AMBANG_BATAS_PELUANG = 0.99
```

```

# Inisialisasi

config = Konfigurasi()
os.makedirs(config.FOLDER_MODEL, exist_ok=True)
os.makedirs(config.FOLDER_OUTPUT, exist_ok=True)
np.random.seed(config.RANDOM_STATE)
random.seed(config.RANDOM_STATE)

print("Inisialisasi selesai. Direktori dan seed telah diatur.")

# ===== SEL 3: MEMUAT DAN MEMPROSES DATA =====

def sederhanakan_nama(nama: str) -> str:
    """Menyederhanakan nama alat ke dalam kategori umum."""
    nama_lower = str(nama).lower()
    if "black magic pocket cinema camera" in nama_lower: return "Black Magic Pocket Cinema Camera"
    if any(term in nama_lower for term in ["camera", "cam", "kamera", "black magic"]): return "Camera"
    if any(term in nama_lower for term in ["baterai", "battery", "batrai"]): return "Battery"
    if any(term in nama_lower for term in ["charger", "carger", "cas"]): return "Charger"
    if any(term in nama_lower for term in ["lensa", "lens"]): return "Lens"
    if any(term in nama_lower for term in ["tripod", "tripot", "libek"]): return "Tripod"
    if any(term in nama_lower for term in ["memory", "memori", "sd card"]): return "Memory"
    if any(term in nama_lower for term in ["lampa", "lighting", "light", "godox"]): return "Lighting"
    if "drone" in nama_lower: return "Drone"
    if "gimbal" in nama_lower: return "Gimbal"
    if any(term in nama_lower for term in ["laptop", "rog"]): return "Laptop"
    return nama_lower.title()

def muat_dan_proses_data(config: Konfigurasi) -> Tuple[pd.DataFrame, Dict[str, List[str]]]:
    """Memuat, membersihkan, dan memproses dataset awal."""
    print("Memuat dan memproses data...")
    path_data = os.path.join(config.FOLDER_DATA, config.NAMA_FILE_DATA)
    try:
        df = pd.read_csv(path_data, sep=";")
    except FileNotFoundError:
        print(f"Error: File data tidak ditemukan di '{path_data}'")
        return pd.DataFrame(), {}

    df.columns = df.columns.str.strip()
    df[config.KOLOM_NAMA_ALAT_SIMPLE] =
    df[config.KOLOM_NAMA_ALAT].apply(sederhanakan_nama)

```

```

peta_nama_asli =
df.groupby(config.KOLOM_NAMA_ALAT_SIMPLE)[config.KOLOM_NAMA_ALAT].uni
que().apply(list).to_dict()

df[config.KOLOM_TANGGAL_PINJAM] =
pd.to_datetime(df[config.KOLOM_TANGGAL_PINJAM], errors='coerce', dayfirst=True)
df.dropna(subset=[config.KOLOM_TANGGAL_PINJAM], inplace=True)
df.dropna(inplace=True)

kelas_valid = df[config.KOLOM_NAMA_ALAT_SIMPLE].value_counts()
kelas_valid = kelas_valid[kelas_valid >= config.MIN_SAMPEL_PER_KELAS].index
df = df[df[config.KOLOM_NAMA_ALAT_SIMPLE].isin(kelas_valid)].copy()

if df.empty:
    print("⚠️ Data kosong setelah pembersihan dan filtering. Proses dihentikan.")

return df, peta_nama_asli

# Jalankan pemuatan data
df, peta_nama_asli = muat_dan_proses_data(config)

if not df.empty:
    print(f"\nData berhasil dimuat. Jumlah baris setelah diproses: {len(df)}")
else:
    print("Proses tidak dapat dilanjutkan karena tidak ada data yang valid.")

# ===== SEL 4: TRAIN-TEST SPLIT & FEATURE ENGINEERING =====

def siapkan_fitur_dan_target(df_latih: pd.DataFrame, df_uji: pd.DataFrame, config:
Konfigurasi) -> Tuple[pd.DataFrame,
pd.Series, pd.DataFrame, pd.Series, LabelEncoder, LabelEncoder, List[str],
pd.DataFrame]:
    """Mempersiapkan fitur dan target untuk model."""
    print("\nMembuat fitur dari data tanggal...")

    for df_temp in [df_latih, df_uji]:
        df_temp["Bulan"] = df_temp[config.KOLOM_TANGGAL_PINJAM].dt.month
        df_temp["Hari_Ke"] = df_temp[config.KOLOM_TANGGAL_PINJAM].dt.dayofweek
        df_temp["Minggu_Ke"] =
df_temp[config.KOLOM_TANGGAL_PINJAM].dt.isocalendar().week.astype(int)

    frekuensi_map =
df_latih[config.KOLOM_NAMA_ALAT_SIMPLE].value_counts().to_dict()

```

```

df_latih["Frekuensi Alat"] =
df_latih[config.KOLOM_NAMA_ALAT_SIMPLE].map(frekuensi_map)
df_uji["Frekuensi Alat"] =
df_uji[config.KOLOM_NAMA_ALAT_SIMPLE].map(frekuensi_map).fillna(0)

encoder_peminjam = LabelEncoder().fit(df_latih[config.KOLOM_NAMA_PEMINJAM])
encoder_alat = LabelEncoder().fit(df_latih[config.KOLOM_NAMA_ALAT_SIMPLE])

df_latih["Peminjam_encoded"] =
encoder_peminjam.transform(df_latih[config.KOLOM_NAMA_PEMINJAM])
df_latih["Alat_encoded"] =
encoder_alat.transform(df_latih[config.KOLOM_NAMA_ALAT_SIMPLE])

df_uji["Peminjam_encoded"] =
df_uji[config.KOLOM_NAMA_PEMINJAM].apply(lambda
x:encoder_peminjam.transform([x])[0]if x in encoder_peminjam.classes_ else -1)
df_uji["Alat_encoded"] = df_uji[config.KOLOM_NAMA_ALAT_SIMPLE].apply(lambda
x:encoder_alat.transform([x])[0]if x in encoder_alat.classes_ else -1)
df_uji = df_uji[(df_uji["Peminjam_encoded"] != -1) & (df_uji["Alat_encoded"] != -1)].copy()

nama_fitur = ["Peminjam_encoded", "Bulan", "Frekuensi Alat", "Hari_Ke", "Minggu_Ke"]
X_latih = df_latih[nama_fitur]
y_latih = df_latih["Alat_encoded"]
X_uji = df_uji[nama_fitur]
y_uji = df_uji["Alat_encoded"]

return X_latih, y_latih, X_uji, y_uji, encoder_peminjam, encoder_alat, nama_fitur, df_latih

if not df.empty:
    print("\nMembagi data menjadi set latih dan uji...")
    df_latih_awal, df_uji_awal = train_test_split(
        df,
        test_size=config.UKURAN_DATA_UJI,
        stratify=df[config.KOLOM_NAMA_ALAT_SIMPLE],
        random_state=config.RANDOM_STATE
    )
    print(f"Ukuran data latih: {len(df_latih_awal)} baris")
    print(f"Ukuran data uji: {len(df_uji_awal)} baris")

# Menyiapkan fitur dan target
X_latih, y_latih, X_uji, y_uji, enc_peminjam, enc_alat, nama_fitur, df_latih_diproses =
siapkan_fitur_dan_target(
    df_latih_awal.copy(), df_uji_awal.copy(), config
)

```

```

print("\nFitur dan target telah disiapkan.")
print("Fitur yang digunakan:", nama_fitur)

# ===== SEL 5: MELATIH & EVALUASI MODEL
=====

def simpan_data_knn_ready(X_latih, y_latih, X_uji, y_uji, nama_fitur, config):
    """Menyimpan data yang sudah di-scale dan di-resample."""
    print("\nMenyimpan data siap pakai untuk KNN (scaled & resampled)...")

    df_latih = pd.DataFrame(X_latih, columns=nama_fitur)
    df_latih['Alat_encoded'] = y_latih

    df_uji = pd.DataFrame(X_uji, columns=nama_fitur)
    df_uji['Alat_encoded'] = y_uji

    path_latih = os.path.join(config.FOLDER_OUTPUT, 'data_latih_knn_ready.csv')
    df_latih.to_csv(path_latih, index=False, sep=';', float_format='%.8f')
    print(f'Data latih siap KNN disimpan ke: {path_latih}')

    path_uji = os.path.join(config.FOLDER_OUTPUT, 'data_uji_knn_ready.csv')
    df_uji.to_csv(path_uji, index=False, sep=';', float_format='%.8f')
    print(f'Data uji siap KNN disimpan ke: {path_uji}')

def hitung_spesifisitas(conf_matrix: np.ndarray, nama_kelas: List[str]):
    """Menghitung dan menampilkan Spesifisitas untuk setiap kelas."""
    print("\nLaporan Spesifisitas (Specificity):")
    for i, nama in enumerate(nama_kelas):
        tn = conf_matrix.sum() - (conf_matrix[i, :].sum() + conf_matrix[:, i].sum() - conf_matrix[i, i])
        fp = conf_matrix[:, i].sum() - conf_matrix[i, i]
        spesifisitas = tn / (tn + fp) if (tn + fp) > 0 else 0
        print(f' - {nama}: {spesifisitas:.2f} %')

def latih_dan_evaluasi_model(X_latih: pd.DataFrame, y_latih: pd.Series, X_uji: pd.DataFrame,
                             y_uji: pd.Series, encoder_alat: LabelEncoder, nama_fitur: List[str], config: "Konfigurasi") -> Tuple[KNeighborsClassifier, StandardScaler]:
    """Melatih, mengoptimalkan, dan mengevaluasi model KNN."""
    print("\nMelakukan scaling data dan menerapkan SMOTE pada data latih...")
    scaler = StandardScaler().fit(X_latih)
    X_latih_scaled = scaler.transform(X_latih)

```

```

X_uji_scaled = scaler.transform(X_uji)

smote_k = min(5, y_latih.value_counts().min() - 1) if y_latih.value_counts().min() > 1 else
1
smote = SMOTE(random_state=config.RANDOM_STATE, k_neighbors=smote_k)
X_latih_res, y_latih_res = smote.fit_resample(X_latih_scaled, y_latih)

simpan_data_knn_ready(X_latih_res, y_latih_res, X_uji_scaled, y_uji.values, nama_fitur,
config)

print("\nMelatih dan mengoptimalkan model dengan GridSearchCV...")
n_splits_cv = min(config.JUMLAH.CV_SPLITS,
pd.Series(y_latih_res).value_counts().min())
if n_splits_cv < 2: n_splits_cv = 2
print(f'Menggunakan n_splits={n_splits_cv} untuk Cross-Validation.')

param_grid = {"n_neighbors": [3, 5, 7, 9], "weights": ["uniform", "distance"], "metric": [
"euclidean", "manhattan"]}
strategi_cv = StratifiedKFold(n_splits=n_splits_cv, shuffle=True,
random_state=config.RANDOM_STATE)

grid_search = GridSearchCV(KNeighborsClassifier(), param_grid, cv=strategi_cv,
n_jobs=-1)
grid_search.fit(X_latih_res, y_latih_res)

# --- KODE TAMBAHAN UNTUK MENAMPILKAN BUKTI PENGUJIAN ---
# Blok ini akan mencetak tabel detail hasil cross-validation
print("\n--- LAPORAN DETAIL HASIL GRIDSEARCHCV ---")
hasil_cv = pd.DataFrame(grid_search.cv_results_)
kolom_penting = [
    'param_n_neighbors', 'param_weights', 'param_metric',
    'mean_test_score', 'std_test_score', 'rank_test_score'
]
# Mengurutkan berdasarkan peringkat untuk melihat hasil terbaik di atas
print("Kinerja Rata-rata Cross-Validation untuk Setiap Kombinasi Parameter:")
# Menggunakan .to_string() agar semua baris dan kolom tercetak dengan baik
print(hasil_cv[kolom_penting].sort_values(by='rank_test_score').to_string())
print("-----\n")
# -----  

# Memilih model terbaik berdasarkan hasil grid search
model_knn_terbaik = grid_search.best_estimator_

print(f"\nParameter Terbaik (dipilih berdasarkan Cross-Validation):"
{grid_search.best_params_})

```

```

# Melakukan prediksi pada data uji
y_pred = model_knn_terbaik.predict(X_uji_scaled)

# Menghitung dan menampilkan akurasi
akurasi = accuracy_score(y_uji, y_pred)
print(f"Akurasi Data Uji (setelah optimasi): {akurasi * 100:.2f}%")

try:
    path_akurasi = os.path.join(config.FOLDER_OUTPUT, "akurasi_model.txt")
    with open(path_akurasi, "w") as f:
        f.write(f'{akurasi:.4f}')
    print(f"Akurasi model disimpan ke: {path_akurasi}")
except Exception as e:
    print(f"! Gagal menyimpan file akurasi: {e}")

# Menampilkan laporan klasifikasi
print("\nLaporan Klasifikasi:")
semua_label = np.unique(y_uji)
nama_target = encoder_alat.inverse_transform(semua_label)
print(classification_report(y_uji, y_pred, labels=semua_label, target_names=nama_target,
                            zero_division=0))

# --- KODE BARU DITAMBAHKAN DI SINI ---
print("\n--- ANALISIS 3 TETANGGA TERDEKAT (CONTOH DARI DATA UJI) ---")
# Ambil beberapa sampel acak dari data uji untuk dianalisis
jumlah_sampel = min(3, len(X_uji_scaled)) # Ambil 3 sampel atau kurang jika data uji sedikit
if jumlah_sampel > 0:
    indeks_sampel = np.random.choice(len(X_uji_scaled), jumlah_sampel, replace=False)

    # Dapatkan 3 tetangga terdekat dari data latih (X_latih_res)
    # Metode kneighbors mengembalikan (jarak, indeks)
    jarak, indeks_tetangga = model_knn_terbaik.kneighbors(X_uji_scaled[indeks_sampel])

    # Loop melalui setiap sampel untuk menampilkan hasilnya
    for i in range(jumlah_sampel):
        # Dapatkan indeks asli dari DataFrame X_uji sebelum di-reset untuk mengambil label asli
        indeks_asli_uji = X_uji.index[indeks_sampel[i]]
        label_asli = encoder_alat.inverse_transform([y_uji.loc[indeks_asli_uji]])[0]
        label_prediksi = encoder_alat.inverse_transform([y_pred[indeks_sampel[i]]])[0]

        print(f"\nSampel Uji #{i+1} (Indeks Asli: {indeks_asli_uji})")
        print(f" -> Label Asli : {label_asli}")
        print(f" -> Prediksi Model: {label_prediksi}")
        print(" -> 3 Tetangga Terdekat dari Data Latih:")

```

```

# Dapatkan label dari 3 tetangga terdekat
labels_tetangga = y_latih_res[indeks_tetangga[i]]
nama_labels_tetangga = encoder_alat.inverse_transform(labels_tetangga)

for j in range(len(nama_labels_tetangga)):
    print(f" - Tetangga {j+1}: Label = {nama_labels_tetangga[j]}: <15, Jarak = {jarak[i][j]:.4f}")
else:
    print("Tidak ada data uji yang cukup untuk menampilkan contoh tetangga.")
print("-----\n")
# --- AKHIR DARI KODE BARU ---

# Menghitung dan menampilkan confusion matrix
cm = confusion_matrix(y_uji, y_pred, labels=semua_label)
hitung_spesifisitas(cm, nama_target)

print("\nMembuat plot Confusion Matrix...")
disp = ConfusionMatrixDisplay(confusion_matrix=cm, display_labels=nama_target)
fig, ax = plt.subplots(figsize=(12, 12))
disp.plot(cmap=plt.cm.Blues, ax=ax, xticks_rotation=45, values_format='d')
ax.set_title("Confusion Matrix (Model KNN)", fontsize=16)
plt.tight_layout()
plt.savefig(os.path.join(config.FOLDER_OUTPUT, "confusion_matrix_final.png"),
dpi=300)
plt.show()

return model_knn_terbaik, scaler
if not df.empty:
    model, scaler = latih_dan_evaluasi_model(
        X_latih, y_latih, X_uji, y_uji, enc_alat, nama_fitur, config
    )

# ===== SEL 6: SIMULASI, VISUALISASI & PENYIMPANAN
=====

def jalankan_simulasi_prediksi(df_latih: pd.DataFrame, model: KNeighborsClassifier,
scaler: StandardScaler, enc_peminjam: LabelEncoder,
enc_alat: LabelEncoder, peta_nama_asli: Dict, nama_fitur: List[str], config: Konfigurasi) -
> pd.DataFrame:
    """Menjalankan simulasi untuk memprediksi peminjaman di masa depan."""
    print(f"\n--- MENJALANKAN SIMULASI UNTUK
{config.TANGGAL_AWAL_SIMULASI} HINGGA
{config.TANGGAL_AKHIR_SIMULASI} ---")

```

```

print(f"--- Hanya menyimpan prediksi dengan peluang >
{config.AMBANG_BATAS_PELUANG*100:.0f}% ---")

prob_harian =
df_latih[config.KOLOM_TANGGAL_PINJAM].dt.dayofweek.value_counts(normalize=True)
)
rentang_tanggal = pd.date_range(start=config.TANGGAL_AWAL_SIMULASI,
end=config.TANGGAL_AKHIR_SIMULASI, freq="D")
peminjam_unik = df_latih[config.KOLOM_NAMA_PEMINJAM].unique()
frekuensi_unik = df_latih["Frekuensi Alat"].unique()

hasil_prediksi = []
for tanggal in rentang_tanggal:
    if prob_harian.get(tanggal.dayofweek, 0) < config.AMBANG_BATAS_TRANSAKSI:
        continue

    for _ in range(config.ITERASI_SIMULASI_PER_HARI):
        try:
            peminjam = random.choice(peminjam_unik)
            peminjam_enc = enc_peminjam.transform([peminjam])[0]

            data_input = pd.DataFrame({
                "Peminjam_encoded": [peminjam_enc], "Bulan": [tanggal.month],
                "Frekuensi Alat": [random.choice(frekuensi_unik)],
                "Hari_Ke": [tanggal.dayofweek], "Minggu_Ke": [tanggal.isocalendar().week]
            })

            input_scaled = scaler.transform(data_input[nama_fitur])

            prediksi_proba = model.predict_proba(input_scaled)[0]
            peluang_tertinggi = np.max(prediksi_proba)

            if peluang_tertinggi > config.AMBANG_BATAS_PELUANG:
                prediksi_encoded = np.argmax(prediksi_proba)
                prediksi_simple = enc_alat.inverse_transform([prediksi_encoded])[0]

                nama_mungkin = peta_nama_asli.get(prediksi_simple, [])
                if nama_mungkin:
                    nama_final = random.choice(nama_mungkin)
                    hasil_prediksi.append({
                        "Tanggal_Prediksi": tanggal,
                        "Alat_Prediksi": nama_final,
                        "Alat_Prediksi_Simplified": prediksi_simple,
                        "Peluang": peluang_tertinggi
                    })

```

```

except Exception:
    continue

return pd.DataFrame(hasil_prediksi)

def buat_grafik_tren_bulanan(df: pd.DataFrame, judul: str, nama_file: str, folder_output: str):
    """Membuat dan menyimpan plot time series bulanan."""
    if df.empty:
        print(f"⚠️ Melewatkkan plot '{judul}' karena tidak ada data.")
        return

    df_agg = df.copy()
    df_agg["Tanggal_Prediksi"] = pd.to_datetime(df_agg["Tanggal_Prediksi"])
    hitungan_bulanan = df_agg.groupby([df_agg['Tanggal_Prediksi']
                                         .dt.month, 'Alat_Prediksi_Simplified']).size().unstack(fill_value=0)
    hitungan_bulanan.index = [calendar.month_name[i] for i in hitungan_bulanan.index]

    plt.style.use('seaborn-v0_8-whitegrid')
    fig, ax = plt.subplots(figsize=(14, 8))
    hitungan_bulanan.plot(kind='line', marker='o', linestyle='-', ax=ax, alpha=0.8)

    ax.set_title(judul, fontsize=18, pad=20)
    ax.set_xlabel("Bulan Prediksi", fontsize=14)
    ax.set_ylabel("Jumlah Prediksi Peminjaman (dari Simulasi)", fontsize=14)
    ax.legend(title='Kategori Alat', bbox_to_anchor=(1.02, 1), loc='upper left')
    ax.grid(True, which='both', linestyle='--', linewidth=0.5)
    plt.xticks(rotation=0)
    fig.tight_layout(rect=[0, 0, 0.85, 1])

    path_file = os.path.join(folder_output, nama_file)
    fig.savefig(path_file, dpi=300)
    print(f"Grafik tren bulanan disimpan ke: {path_file}")
    plt.show()
    plt.close(fig)

def buat_grafik_tren_periode(df: pd.DataFrame, judul: str, nama_file: str, folder_output: str):
    """Membuat dan menyimpan plot time series untuk periode tertentu."""
    if df.empty:
        print(f"⚠️ Melewatkkan plot '{judul}' karena tidak ada data.")
        return

    df_agg = df.copy()
    df_agg["Tanggal_Prediksi"] = pd.to_datetime(df_agg["Tanggal_Prediksi"])
    data_agg = df_agg.groupby([pd.Grouper(key='Tanggal_Prediksi', freq='D'),
                               'Alat_Prediksi_Simplified']).size().unstack(fill_value=0)

```

```

plt.style.use('seaborn-v0_8-whitegrid')
fig, ax = plt.subplots(figsize=(15, 8))
data_agg.plot(kind='line', marker='o', linestyle='-', alpha=0.8, ax=ax)

ax.set_title(judul, fontsize=18)
ax.set_ylabel("Jumlah Prediksi Peminjaman", fontsize=14)
ax.legend(title='Kategori Alat', bbox_to_anchor=(1.02, 1), loc='upper left')
ax.grid(True, which='both', linestyle='--', linewidth=0.5)

jumlah_bulan = len(df_agg['Tanggal_Prediksi'].dt.month.unique())
format_tanggal = mdates.DateFormatter('%d %b' if jumlah_bulan > 1 else '%d')
ax.set_xlabel(f'Hari di Bulan {df_agg["Tanggal_Prediksi"].dt.month_name().iloc[0]}')
if jumlah_bulan == 1 else "Periode", fontsize=14)
ax.xaxis.set_major_formatter(format_tanggal)
fig.autofmt_xdate(rotation=15, ha='right')
fig.tight_layout(rect=[0, 0, 0.85, 1])

path_file = os.path.join(folder_output, nama_file)
fig.savefig(path_file, dpi=300)
print(f"Grafik detail disimpan ke: {path_file}")
plt.show()
plt.close(fig)

def buat_visualisasi(df_prediksi: pd.DataFrame, config: Konfigurasi):
    """Membuat dan menyimpan semua visualisasi dari hasil simulasi."""
    if df_prediksi.empty:
        print("\n⚠️ Tidak ada prediksi yang dihasilkan (setelah filtering peluang), visualisasi dilewati.")
        return

    path_prediksi = os.path.join(config.FOLDER_OUTPUT,
                                "hasil_prediksi_harian_difilter.csv")
    df_prediksi.to_csv(path_prediksi, index=False, sep=',', float_format='%.4f')
    print(f"\nPrediksi harian yang difilter disimpan ke '{path_prediksi}'")

    print("\nMembuat grafik utama (tren bulanan)...")
    judul_grafik = "Prediksi Tren Peminjaman Bulanan"
    buat_grafik_tren_bulanan(df_prediksi, judul_grafik, "grafik_tren_bulanan_difilter.png",
                             config.FOLDER_OUTPUT)

    print("\nMembuat grafik detail untuk analisis mendalam...")
    for bulan_num in sorted(df_prediksi['Tanggal_Prediksi'].dt.month.unique()):
        nama_bulan = calendar.month_name[bulan_num]
        df_bulanan = df_prediksi[df_prediksi['Tanggal_Prediksi'].dt.month == bulan_num]

```

```

judul_grafik_detail = f"Prediksi Tren Detail - {nama_bulan} 2025"
buat_grafik_tren_periode(df_bulanan, judul_grafik_detail,
f"grafik_detail_{nama_bulan.lower()}_difilter.png",
config.FOLDER_OUTPUT)

if not df.empty:
    df_prediksi = jalankan_simulasi_prediksi(
        df_latih_diproses, model, scaler, enc_peminjam, enc_alat, peta_nama_asli, nama_fitur,
        config
    )
    if not df_prediksi.empty:
        print(f"\nSimulasi selesai. Dihasilkan {len(df_prediksi)} prediksi yang valid.")
        buat_visualisasi(df_prediksi, config)
    else:
        print("\nSimulasi selesai, namun tidak ada prediksi yang memenuhi ambang batas
peluang.")

```

----- SEL 7: MENYIMPAN ARTEFAK -----

```

def simpan_artefak(model, scaler, enc_alat, enc_peminjam, peta_nama_asli, config:
Konfigurasi):
    """Menyimpan semua artefak model ke dalam file pickle."""
    print("\nMenyimpan model dan objek preprocessing...")
    artefak = {
        "model_knn_final.pkl": model,
        "scaler_final.pkl": scaler,
        "encoder_alat_final.pkl": enc_alat,
        "encoder_peminjam_final.pkl": enc_peminjam,
        "original_name_map.pkl": peta_nama_asli
    }
    for nama_file, obj in artefak.items():
        with open(os.path.join(config.FOLDER_MODEL, nama_file), "wb") as f:
            pickle.dump(obj, f)
    print("Semua artefak berhasil disimpan.")

```

```

if not df.empty:
    simpan_artefak(model, scaler, enc_alat, enc_peminjam, peta_nama_asli, config)
    print("\n--- Proses Selesai ---")
else:
    print("\n--- Proses Dihentikan (Tidak ada data valid) ---")

```

Lampiran 3 Hasil prediksi

1	Tanggal_Prediksi	Alat_Prediksi_Simplified
2	01/05/2025	Sony Ag
3	01/05/2025	Lens
4	01/05/2025	Charger
5	01/05/2025	Drone
6	01/05/2025	Camera
7	01/05/2025	Drone
8	01/05/2025	Sony Ag
9	01/05/2025	Lens
10	01/05/2025	Lens
11	02/05/2025	Lens
12	02/05/2025	Soliton
13	02/05/2025	Camera
14	02/05/2025	Charger
15	02/05/2025	Battery
16	02/05/2025	Camera
17	02/05/2025	Battery
18	02/05/2025	Soliton
19	02/05/2025	Gimbal
20	05/05/2025	Drone
21	05/05/2025	Gimbal
22	05/05/2025	Battery
23	05/05/2025	Lens
24	05/05/2025	Gimbal
25	05/05/2025	Lens
26	05/05/2025	Lens
27	05/05/2025	Memory
34	08/05/2025	Tripod
35	08/05/2025	Sony Ag
36	08/05/2025	Battery
37	08/05/2025	Memory
38	08/05/2025	Camera
39	09/05/2025	Lighting
40	09/05/2025	Sony Ag
41	09/05/2025	Gimbal
42	09/05/2025	Lens
43	09/05/2025	Gimbal
44	09/05/2025	Gimbal
45	09/05/2025	Lens
46	12/05/2025	Drone
47	12/05/2025	Lens
48	12/05/2025	Charger
49	12/05/2025	Drone
50	12/05/2025	Camera
51	12/05/2025	Gimbal
52	12/05/2025	Lens
53	12/05/2025	Lens
54	12/05/2025	Drone
55	15/05/2025	Lens
56	15/05/2025	Sony Ag
57	15/05/2025	Drone
58	15/05/2025	Drone
59	15/05/2025	Drone
60	15/05/2025	Lens

74	19/05/2025	Lens
75	19/05/2025	Lens
76	19/05/2025	Gimbal
77	19/05/2025	Lens
78	22/05/2025	Memory
79	22/05/2025	Battery
80	22/05/2025	Lens
81	22/05/2025	Memory
82	22/05/2025	Charger
83	22/05/2025	Mixer Data Video
84	22/05/2025	Sony Ag
85	23/05/2025	Camera
86	23/05/2025	Sony Ag
87	23/05/2025	Camera
88	23/05/2025	Soliton
89	23/05/2025	Sony Ag
90	23/05/2025	Camera
91	23/05/2025	Soliton
92	23/05/2025	Lighting
93	23/05/2025	Memory
94	23/05/2025	Charger
95	26/05/2025	Charger
96	26/05/2025	Gimbal
97	26/05/2025	Lens
98	26/05/2025	Gimbal
99	26/05/2025	Tripod
00	26/05/2025	Lens
101	26/05/2025	Camera
102	26/05/2025	Lens
103	26/05/2025	Memory
104	26/05/2025	Tripod
105	29/05/2025	Sony Ag
106	29/05/2025	Camera
107	29/05/2025	Drone
108	29/05/2025	Gimbal
109	29/05/2025	Lens
110	29/05/2025	Mixer Data Video
111	29/05/2025	Battery
112	29/05/2025	Sony Alpha
113	29/05/2025	Drone
114	30/05/2025	Lumix
115	30/05/2025	Lens
116	30/05/2025	Gimbal
117	30/05/2025	Lighting
118	30/05/2025	Lumix
119	30/05/2025	Soliton
120	30/05/2025	Soliton
121	30/05/2025	Sony Ag
122	30/05/2025	Lens
123	02/06/2025	Gimbal
124	02/06/2025	Charger
125	02/06/2025	Charger
126	02/06/2025	Gimbal

164	13/06/2025	Lens
165	13/06/2025	Lens
166	13/06/2025	Charger
167	13/06/2025	Gimbal
168	13/06/2025	Battery
169	16/06/2025	Camera
170	16/06/2025	Gimbal
171	16/06/2025	Sony Ag
172	16/06/2025	Gimbal
173	16/06/2025	Battery
174	16/06/2025	Battery
175	16/06/2025	Gimbal
176	16/06/2025	Gimbal
177	19/06/2025	Camera
178	19/06/2025	Mixer Data Video
179	19/06/2025	Camera
180	19/06/2025	Gimbal
181	19/06/2025	Battery
182	19/06/2025	Lens
183	19/06/2025	Sony Ag
184	19/06/2025	Camera
185	20/06/2025	Gimbal
186	20/06/2025	Camera
187	20/06/2025	Camera
188	20/06/2025	Lens
189	20/06/2025	Lumix
190	20/06/2025	Lens
211	27/06/2025	Gimbal
212	27/06/2025	Gimbal
213	27/06/2025	Battery
214	27/06/2025	Soliton
215	27/06/2025	Gimbal
216	27/06/2025	Lens
217	30/06/2025	Gimbal
218	30/06/2025	Sony Ag
219	30/06/2025	Charger
220	30/06/2025	Gimbal
221	30/06/2025	Lens
222	30/06/2025	Battery
223	30/06/2025	Charger
224	30/06/2025	Camera
225	30/06/2025	Gimbal
226	30/06/2025	Camera
227	03/07/2025	Mixer Data Video
228	03/07/2025	Camera
229	03/07/2025	Mixer Data Video
230	03/07/2025	Mixer Data Video
231	03/07/2025	Tripod
232	03/07/2025	Sony Ag
233	03/07/2025	Camera
234	03/07/2025	Sony Ag
235	03/07/2025	Lens
236	04/07/2025	Camera
237	04/07/2025	Gimbal

242	04/07/2025	Mixer Data Video
243	04/07/2025	Charger
244	07/07/2025	Tripod
245	07/07/2025	Battery
246	07/07/2025	Battery
247	07/07/2025	Camera
248	07/07/2025	Camera
249	07/07/2025	Gimbal
250	07/07/2025	Gimbal
251	07/07/2025	Battery
252	07/07/2025	Gimbal
253	07/07/2025	Tripod
254	10/07/2025	Lighting
255	10/07/2025	Tripod
256	10/07/2025	Lighting
257	10/07/2025	Gimbal
258	10/07/2025	Lighting
259	10/07/2025	Lens
260	10/07/2025	Sony Alpha
261	10/07/2025	Lighting
262	10/07/2025	Sony Alpha
263	11/07/2025	Mixer Data Video
264	11/07/2025	Lumix
265	11/07/2025	Gimbal
266	11/07/2025	Lumix
267	11/07/2025	Lumix
302	24/07/2025	Sony Ag
303	24/07/2025	Lens
304	24/07/2025	Battery
305	24/07/2025	Sony Alpha
306	24/07/2025	Tripod
307	25/07/2025	Lumix
308	25/07/2025	Tripod
309	25/07/2025	Battery
310	25/07/2025	Charger
311	25/07/2025	Gimbal
312	28/07/2025	Tripod
313	28/07/2025	Gimbal
314	28/07/2025	Sony Ag
315	28/07/2025	Sony Ag
316	28/07/2025	Sony Ag
317	28/07/2025	Sony Ag
318	28/07/2025	Sony Ag
319	31/07/2025	Mixer Data Video
320	31/07/2025	Sony Alpha
321	31/07/2025	Charger
322	31/07/2025	Gimbal
323	31/07/2025	Lighting
324	31/07/2025	Tripod
325	31/07/2025	Mixer Data Video
326	31/07/2025	Memory
327	31/07/2025	Gimbal

Lampiran 4. Permohonan penelitian

Nomor : 024/05/IF/C,4-VI/V/16/2025 Makassar, 14 Muharam 1447 H
Lamp : - 10 Juli 2025 M
Hal : Permohonan Data Penelitian

Kepada Yang Terhormat,
Ketua Program Studi Informatika
Di -
Tempat

Assalamualaikum Warahmatullahi Wabarakatuh

Dengan Rahmat Allah SWT, Semoga aktivitas kita bermilai ibadah di Sisi-Nya. Dalam rangka penyelesaian Tugas Akhir pada Studi Informatika dengan judul "Penerapan Algoritma K-Nearest Neighbor dalam Analisis Peminjaman Barang pada Divisi Inventaris TVRI Makassar

Stambuk	Nama
105841104921	Risal

Sehubungan dengan hal tersebut, maka kami memohon dibuatkan surat pengantar pada instansi di bawah ini:

Nama Instansi : TVRI Sulawesi Selatan
Alamat : Jl. Pajonga Dg. Ngalle No.14, Mario, Kec. Mariso, Kota Makassar, Sulawesi Selatan 90122
Demikian surat kami atas perhatian dan kerja samanya kami hantarkan banyak terima kasih.

Jazakumullah Khaeran Katsiran,
Wassalamu Alaikum Warahmatullahi wabarakatuh.

Yang Mengusulkan:
Risal
105841104921

Lampiran 5. Surat Rekomendasi Penelitian dari LP3M



Lampiran 6. Surat Izin Penelitian dari PTSP



Lampiran 7. Surat Izin Penelitian dari Dinas TVRI Sulawesi Selatan



Lampiran 8. Hasil Turniting

**MAJELIS PENDIDIKAN TINGGI PIMPINAN PUSAT MUHAMMADIYAH
UNIVERSITAS MUHAMMADIYAH MAKASSAR
UPT PERPUSTAKAAN DAN PENERBITAN**
Alamat Kantor : Jl. Sultan Alauddin No. 259 Makassar 90222 Tlp. (0411) 866972, 881593, Fax (0411) 865588

.....

SURAT KETERANGAN BEBAS PLAGIAT

UPT Perpustakaan dan Penerbitan Universitas Muhammadiyah Makassar,
Menerangkan bahwa mahasiswa yang tersebut namanya di bawah ini:

Nama : Risal
Nim : 105841104921
Program Studi : Teknik Informatika

Dengan nilai:

No	Bab	Nilai	Ambang Batas
1	Bab 1	8%	10 %
2	Bab 2	8%	25 %
3	Bab 3	3%	10 %
4	Bab 4	5%	10 %
5	Bab 5	4%	5 %

Dinyatakan telah lulus cek plagiat yang diadakan oleh UPT- Perpustakaan dan Penerbitan
Universitas Muhammadiyah Makassar Menggunakan Aplikasi Turnitin.

Demikian surat keterangan ini diberikan kepada yang bersangkutan untuk dipergunakan
seperlunya.

Makassar, 26 Agustus 2025
Mengetahui,

Kepala UPT- Perpustakaan dan Penerbitan,


Nursihapati Homa, M.I.P
BAP 964-591

Jl. Sultan Alauddin no 259 makassar 90222
Telepon (0411)866972,881 593,fax (0411)865 588
Website: www.library.unismuh.ac.id
E-mail : perpustakaan@unismuh.ac.id

Lampiran 9. Hasil turniting bab 1-5



BAB I Risal 105841104921

ORIGINALITY REPORT

8% SIMILARITY INDEX 8% INTERNET SOURCES 4% PUBLICATIONS % STUDENT PAPERS

PRIMARY SOURCES

1 repository.upnj.ac.id
Internet Source

2 repository.unib.ac.id
Internet Source

3 repository.uncp.ac.id
Internet Source

5%

2%

2%

Exclude quotes

Exclude bibliography

Exclude matches



BAB II Risal 105841104921

by Tahap Tutup

Submission date: 25-Aug-2025 01:01PM (UTC+0700)
Submission ID: 2734825678
File name: BAB_II.docx (149.95K)
Word count: 2138
Character count: 14928

BAB II Risal 105841104921

ORIGINALITY REPORT

8%
SIMILARITY INDEX

8%
INTERNET SOURCES

4%
PUBLICATIONS

%
STUDENT PAPERS

PRIMARY SOURCES

1	ejournal.ikado.ac.id Internet Source	1%
2	text-id.123dok.com Internet Source	1%
3	Zaenul Amri, Muhammad Rodi, M. Nurul Wathani, Amir Bagja, Zulkipli. "Prediksi Diabetes Menggunakan Algoritma K-Nearest (KNN) Teknik SMOTE-ENN", Infotek: Jurnal Informatika dan Teknologi, 2025 Publication	1%
4	eprints.itn.ac.id Internet Source	1%
5	id.scribd.com Internet Source	1%
6	Ni Putu Irene Pasca Nurahdika, Joko Sutopo. "Analisa Performa Convolution Neural Network Dalam Pengenalan Tulisan Tangan Aksara Lontara", INTECOMS: Journal of Information Technology and Computer Science, 2025 Publication	<1%
7	adoc.pub Internet Source	<1%
8	digilib.uns.ac.id Internet Source	<1%

BAB III Risal 105841104921

by Tahap Tutup

Submission date: 26-Aug-2025 09:46AM (UTC+0700)
Submission ID: 2735367483
File name: BAB_III_1.docx (3.18M)
Word count: 5347
Character count: 34472

BAB III Risal 105841104921

ORIGINALITY REPORT

3% SIMILARITY INDEX 3% INTERNET SOURCES % PUBLICATIONS 2% STUDENT PAPERS

PRIMARY SOURCES

1	digilibadmin.unismuh.ac.id Internet Source	<1%
2	Submitted to Liverpool John Moores University Student Paper	<1%
3	Submitted to Universitas Budi Luhur Student Paper	<1%
4	Submitted to College of the Canyons Student Paper	<1%
5	pa-surakarta.go.id Internet Source	<1%
6	smartech.gatech.edu Internet Source	<1%
7	repository.umpwr.ac.id:8080 Internet Source	<1%
8	Submitted to Universitas Muslim Indonesia Student Paper	<1%
9	medium.com Internet Source	<1%
10	Submitted to UIN Syarif Hidayatullah Jakarta Student Paper	<1%
11	data4basketball.com Internet Source	<1%

BAB IV Risal 105841104921

by Tahap Tutup

Submission date: 25-Aug-2025 01:02PM (UTC+0700)

Submission ID: 2734826152

File name: BAB_IV.docx (3.18M)

Word count: 5347

Character count: 34472

BAB IV Risal 105841104921

ORIGINALITY REPORT





BAB V RISAL 105841104921

ORIGINALITY REPORT



PRIMARY SOURCES

1 docobook.com
Internet Source

4%

Exclude quotes

Exclude bibliography

Exclude matches

