

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

Risal¹⁾, Chyquitha Danuputri²⁾, Darniati*³⁾, Muhyiddin AM Hayat⁴⁾

1. Informatika, Universitas Muhammadiyah Makassar
105841104921@student.unismuh.ac.id
2. Informatika, Universitas Muhammadiyah Makassar
chyquithadanuputri@unismuh.ac.id
3. Informatika, Universitas Muhammadiyah Makassar
darniati@unismuh.ac.id
4. Informatika, Universitas Muhammadiyah Makassar
muhyiddin@unismuh.ac.id

Abstract

Inventory management in the TVRI Makassar Inventory Division is inefficient due to the lack of a predictive system, hampering proactive asset requirement planning. This study aims to apply the K-Nearest Neighbor (KNN) algorithm to analyze historical borrowing patterns, predict demand for goods three months in advance, and evaluate model accuracy. Using a quantitative approach, this study implements a systematic machine learning workflow, including data preprocessing, temporal feature engineering, class imbalance handling using the Synthetic Minority Over-sampling Technique (SMOTE), and hyperparameter optimization using GridSearchCV. The results show that the optimized KNN model achieved an overall accuracy of 80.18%, significantly outperforming the baseline model. Key findings revealed that the model's performance is contextual, with very high reliability (F1-Score > 0.95) on frequently borrowed assets, and is able to identify strong temporal demand patterns. It is concluded that KNN is effective for segmented inventory demand prediction and has the potential to serve as a basis for TVRI Makassar to adopt a proactive, data-driven inventory management strategy, enabling more efficient resource allocation.

Kata Kunci : *K-Nearest Neighbor, Inventory Management, SMOTE, Predictive Analysis, Data Mining*

A. PENDAHULUAN

Efisiensi pengelolaan aset merupakan pilar fundamental bagi keberlangsungan operasional lembaga penyiaran publik seperti Televisi Republik Indonesia (TVRI). Ketersediaan dan pemanfaatan inventaris secara optimal menjadi faktor krusial yang menentukan kelancaran kegiatan siaran dan produksi. Namun, Divisi Inventaris TVRI Makassar

menghadapi tantangan signifikan dalam optimalisasi manajemen asetnya, karena tidak adanya sistem prediksi yang mampu memproyeksikan kebutuhan di masa depan. Keterbatasan ini mengakibatkan kesulitan dalam melakukan analisis prediktif untuk perencanaan kebutuhan aset secara proaktif, sehingga berpotensi menimbulkan inefisiensi alokasi sumber

daya dan mengganggu kesiapan operasional [1]

Permasalahan ini bukan merupakan anomali, melainkan cerminan dari isu yang lebih luas di berbagai organisasi di mana ketidakakuratan data dan kesulitan pelacakan aset menjadi penghambat utama efisiensi [2]. Ketidaksesuaian antara data stok dengan kondisi fisik serta minimnya pemantauan pergerakan aset dapat berujung pada penumpukan barang yang tidak perlu, peningkatan biaya operasional, atau sebaliknya, kekurangan aset kritis pada saat genting [3]. Konsekuensinya, perencanaan strategis terkait perawatan, pengadaan, dan alokasi inventaris menjadi kurang tepat sasaran dan tidak berbasis data yang kuat [4].

Menjawab tantangan tersebut, pemanfaatan teknik data mining menawarkan pendekatan berbasis bukti untuk mentransformasi data historis menjadi wawasan yang dapat ditindaklanjuti [5]. Secara khusus, algoritma *K-Nearest Neighbor* (KNN) diajukan sebagai solusi potensial. KNN merupakan metode klasifikasi non-parametrik yang dikenal karena kesederhanaan konseptual dan kemampuannya mengidentifikasi pola berdasarkan kedekatan data historis tanpa memerlukan asumsi distribusi data yang kompleks [6]. Relevansi penerapan KNN diperkuat oleh keberhasilannya dalam konteks serupa, seperti analisis pola peminjaman di perpustakaan [7] dan prediksi item terlaris untuk manajemen stok [8]. Meskipun demikian, penerapan KNN untuk analisis prediktif peminjaman aset operasional di lembaga penyiaran publik merupakan area yang belum banyak dieksplorasi, sehingga menyisakan celah penelitian (*research gap*) yang signifikan.

Berdasarkan latar belakang dan celah penelitian tersebut, penelitian ini dirumuskan untuk menjawab pertanyaan fundamental: Bagaimana penerapan

algoritma *K-Nearest Neighbor* (KNN) dalam menganalisis pola peminjaman barang pada Divisi *Inventaris* TVRI Makassar?, dan Bagaimana tingkat akurasi dari algoritma *K-Nearest Neighbor* (KNN) terhadap data peminjaman barang pada Divisi *Inventaris* TVRI Makassar?. Sejalan dengan itu, tujuan penelitian ini adalah (1) membangun dan mengimplementasikan model klasifikasi menggunakan algoritma KNN untuk mengidentifikasi pola dan memprediksi barang yang berpotensi tinggi untuk dipinjam pada periode tiga bulan mendatang, serta (2) mengevaluasi kinerja model secara kuantitatif melalui metrik akurasi. Penelitian ini diharapkan dapat memberikan kontribusi ilmiah berupa bukti empiris mengenai kelayakan KNN dalam domain manajemen *inventaris* lembaga penyiaran, sekaligus menghasilkan model prediktif yang dapat menjadi alat bantu pengambilan keputusan strategis bagi manajemen TVRI Makassar.

B. METODE PENELITIAN

Penelitian ini menerapkan pendekatan kuantitatif dengan alur kerja *machine learning* yang terstruktur untuk menganalisis dan memprediksi pola peminjaman *inventaris*. Tahapan penelitian dirancang secara sistematis untuk memastikan validitas dan reliabilitas hasil, yang diuraikan sebagai berikut.

1. Pengambilan dan Pra-pemrosesan Data

Tahap awal penelitian adalah pengambilan data (*data acquisition*). Data yang digunakan merupakan data sekunder berupa catatan historis transaksi peminjaman barang dari Divisi *Inventaris* TVRI Makassar. Dataset mentah ini yang berbentuk tabular, kemudian melalui tahap pra-pemrosesan (*preprocessing*)

yang krusial untuk memastikan kualitas dan konsistensi data. Proses ini mencakup:

- a) pembersihan data, yaitu menangani nilai yang hilang (missing values) dan melakukan standardisasi entri data yang tidak konsisten (misalnya, variasi penulisan nama alat seperti "Camera" dan "kamera" diseragamkan); dan
 - b) transformasi data di mana kolom tanggal diubah ke format datetime standar untuk memungkinkan analisis temporal.
2. Pemisahan Data, Rekayasa Fitur, dan Encoding

Setelah data bersih, dilakukan pemisahan dataset menjadi dua subset independen: data latih (80%) dan data uji (20%). Pembagian ini menggunakan fungsi `train_test_split` dengan parameter stratifikasi (*stratify*) untuk memastikan proporsi setiap kelas aset tetap terjaga di kedua subset, sebuah langkah penting untuk menangani data yang tidak seimbang dan mencegah bias evaluasi. Selanjutnya, dilakukan rekayasa fitur (*feature engineering*) pada kedua subset untuk menciptakan variabel prediktor yang lebih informatif. Fitur-fitur baru seperti Bulan, Hari_Ke (hari dalam seminggu), dan Minggu_Ke (minggu dalam setahun) diekstrak dari kolom tanggal. Terakhir, dilakukan proses *encoding*, di mana semua fitur kategorikal (seperti nama alat dan unit peminjam) diubah menjadi representasi numerik menggunakan *LabelEncoder*, karena algoritma KNN beroperasi pada data numerik.


3. Penskalaan Fitur dan Penanganan Ketidakseimbangan kelas

Mengingat algoritma KNN berbasis jarak dan sangat sensitif terhadap skala fitur, penskalaan fitur (*feature scaling*) diterapkan menggunakan *StandardScaler*. Proses ini menormalkan setiap fitur numerik sehingga memiliki rata-rata 0 dan

standar deviasi 1. Scaler ini "dilatih" (fit) hanya pada data latih dan kemudian digunakan untuk mentransformasi data latih dan data uji guna mencegah kebocoran data (*data leakage*). Selanjutnya, untuk mengatasi masalah distribusi kelas yang tidak seimbang, di mana beberapa barang sangat jarang dipinjam, teknik *oversampling SMOTE (Synthetic Minority Over-sampling Technique)* diterapkan [9]. SMOTE bekerja dengan menciptakan sampel sintetis untuk kelas-kelas minoritas. Penting untuk dicatat bahwa teknik ini hanya diterapkan pada data latih untuk memastikan data uji tetap merepresentasikan data dunia nyata yang belum pernah dilihat model.

4. Evaluasi Model KNN dan Analisis Prediktif

Inti dari penelitian ini adalah evaluasi kinerja model KNN. Konfigurasi *hiperparameter* terbaik (meliputi jumlah tetangga *k*, metrik jarak, dan metode pembobotan) dicari secara sistematis menggunakan *GridSearchCV* dengan validasi silang pada data latih. Model dengan konfigurasi optimal kemudian dievaluasi performanya pada data uji menggunakan metrik standar seperti Akurasi, Presisi, Recall, dan F1-Score, yang dianalisis melalui *confusion matrix* [10]. Setelah model tervalidasi tahap akhir adalah analisis prediktif, di mana model digunakan untuk menyimulasikan permintaan barang harian selama periode tiga bulan ke depan (Mei–Juli 2025). Hasil dari simulasi ini bukanlah ramalan tunggal, melainkan serangkaian proyeksi yang membentuk tren permintaan, yang kemudian dianalisis untuk memberikan wawasan strategis bagi manajemen inventaris.



Gambar 1 Perancangan system

C. HASIL DAN PEMBAHASAN


Bagian ini menyajikan hasil dari implementasi dan evaluasi model *K-Nearest Neighbor* (KNN) serta analisis mendalam terhadap proyeksi permintaan *inventaris*. Pembahasan akan dibagi menjadi tiga sub-bagian utama evaluasi kinerja model, analisis tren agregat, dan analisis fluktuasi permintaan harian.

1. Kinerja dan Evaluasi Model

Klasifikasi

Langkah pertama dalam analisis adalah mengevaluasi kinerja model KNN yang telah dioptimalkan. Evaluasi ini bertujuan untuk memvalidasi seberapa akurat model dalam mengklasifikasikan

data peminjaman yang belum pernah dilihat sebelumnya. Kinerja model secara detail di visualisasikan menggunakan Confusion Matrix pada dibawah ini.



Gambar 2. Confusion Matrix Hasil Evaluasi Model KNN


Analisis Confusion

Matrix memberikan gambaran komprehensif tentang kekuatan dan kelemahan model. Nilai-nilai yang terkonsentrasi di sepanjang diagonal utama, seperti pada kelas Battery (53 prediksi benar) dan Camera (39 prediksi benar), menunjukkan bahwa model memiliki akurasi yang sangat tinggi dalam mengidentifikasi kedua aset vital ini. Namun, matriks ini juga mengungkap area di mana model mengalami kesulitan. Sebagai contoh, terdapat beberapa kasus di mana Lensa salah diklasifikasikan sebagai Charger (3 kasus) dan Lighting (1 kasus). Demikian pula, Tripod beberapa kali keliru diprediksi sebagai Memory (9 kasus). Kesalahan klasifikasi ini umumnya terjadi pada aset dengan volume data yang lebih sedikit atau memiliki pola penggunaan yang tumpang tindih dengan aset lain. Temuan ini mengindikasikan bahwa kinerja model bersifat kontekstual

dan sangat dipengaruhi oleh kualitas data historis per kategori.

2. Proyeksi Tren Peminjaman Agregat

Setelah model divalidasi, model tersebut digunakan untuk menyimulasikan permintaan inventaris selama periode tiga bulan ke depan (Mei–Juli 2025). Hasil simulasi secara agregat per bulan disajikan dalam Gambar 3 untuk memberikan gambaran strategis mengenai tren permintaan jangka menengah.




Gambar 3. Proyeksi Tren Peminjaman Agregat (Mei-Juli 2025)


Analisis Gambar Grafik tren bulanan menunjukkan dinamika permintaan yang bervariasi antar aset. Terlihat jelas bahwa Lensa (garis coklat) dan Gimbal (garis ungu) diproyeksikan menjadi aset dengan permintaan tertinggi secara keseluruhan, meskipun trennya fluktuatif. Permintaan untuk Camera (garis oranye) menunjukkan tren yang lebih stabil dan meningkat menuju bulan Juli. Sebaliknya, beberapa aset seperti Soliton (garis biru muda) menunjukkan volume prediksi yang sangat rendah. Grafik ini sangat berguna untuk perencanaan strategis, seperti alokasi anggaran pengadaan atau penjadwalan perawatan preventif, dengan memfokuskan perhatian pada aset-aset yang diprediksi memiliki permintaan tinggi.

3. Analisis Fluktuasi Permintaan Harian


Untuk mendapatkan wawasan yang lebih operasional, analisis dilanjutkan dengan memecah tren agregat menjadi fluktuasi permintaan harian. Gambar 3, 4, dan 5 menyajikan proyeksi permintaan harian untuk bulan Mei, Juni, dan Juli secara berurutan.



Gambar 4. Detail Prediksi Peminjaman - Mei 2025



Gambar 5. Detail Prediksi Peminjaman - Juni 2025



Gambar 6. Detail Prediksi Peminjaman - Juli 2025

Analisis Gambar 4, 5, dan 6: Analisis pada tingkat harian ini mengungkap pola-pola yang tidak terlihat pada grafik

agregat. Beberapa temuan kunci antara lain:

- a) Pola Mingguan yang Kuat Puncak-puncak permintaan untuk berbagai aset, terutama Gimbal dan Lensa, secara konsisten terjadi pada hari kerja dan cenderung menurun drastis pada akhir pekan. Ini mengonfirmasi adanya ritme operasional mingguan yang berhasil ditangkap oleh model.
- b) Identifikasi Hari Puncak Grafik ini memungkinkan identifikasi hari-hari spesifik dengan potensi permintaan tinggi. Misalnya, pada bulan Mei (Gambar 4), permintaan Gimbal dan Lensa mencapai puncaknya sekitar tanggal 17 dan 21. Pada bulan Juni (Gambar 5), Gimbal menunjukkan lonjakan permintaan yang sangat signifikan sekitar tanggal 21.
- c) Dinamika Permintaan Antar-Bulan Terjadi pergeseran dominasi aset dari bulan ke bulan. Jika pada bulan Juni Gimbal sangat dominan, pada bulan Juli (Gambar 6) permintaan untuk Sony Ag (garis biru kehijauan) dan Lumix (garis abu-abu) menunjukkan lonjakan yang signifikan. Hal ini menunjukkan kemampuan model untuk beradaptasi dengan potensi perubahan kebutuhan operasional seiring waktu.

D. KESIMPULAN DAN SARAN

Penelitian ini berhasil menunjukkan bahwa algoritma *K-Nearest Neighbor* (KNN) dapat diterapkan secara efektif untuk menganalisis dan memprediksi pola peminjaman *inventaris* di Divisi Inventaris TVRI Makassar. Melalui alur kerja machine learning yang komprehensif, model mencapai tingkat akurasi keseluruhan yang solid sebesar 80,18%, namun dengan kinerja yang bersifat kontekstual dan tersegmentasi model menunjukkan

keandalan sangat tinggi pada aset dengan volume data historis yang melimpah. Secara strategis, model ini terbukti mampu mengidentifikasi pola permintaan temporal mingguan dan menghasilkan daftar pantauan (*watchlist*) dinamis yang akurat untuk aset-aset krusial. Implikasi praktisnya adalah bahwa model ini dapat menjadi dasar bagi manajemen untuk beralih ke strategi pengelolaan *inventaris* yang lebih proaktif dan berbasis data, memungkinkan alokasi sumber daya yang lebih efisien.

Meskipun demikian penelitian ini memiliki keterbatasan, terutama ketergantungan model pada data historis yang membatasi kemampuannya dalam mengantisipasi permintaan dari kejadian baru, serta kinerja yang lebih rendah pada kategori aset dengan data yang sangat terbatas. Oleh karena itu, penelitian selanjutnya disarankan untuk mengeksplorasi

algoritma ensemble seperti Random Forest atau Gradient Boosting yang berpotensi lebih tangguh dalam menangani ketidakseimbangan kelas. Selain itu pengintegrasian fitur-fitur eksternal, seperti jadwal siaran khusus atau proyek lapangan, dapat menjadi langkah berikutnya untuk meningkatkan akurasi dan kapabilitas prediktif model.

E. REFERENSI

- [1] Malik, R. R., Rizal, E., & Rodiah, S. (2023). Pengelolaan aset digital di Library SCTV. *Jurnal Ilmu Komputer (JUKIM)*, 2(5). <https://doi.org/10.56127/jukim.v2i05>
- [2] Pranoto, A. O., & Sedyono, E. (2021). Perancangan sistem informasi inventaris barang berbasis web. *Jurnal Teknik Informatika dan Sistem Informasi*

- (JUTISI), 7(2).
<https://doi.org/10.28932/jutisi.v7i2.3597>
- [3] Hijrah, & Maulidar. (2021). Analisis dan perancangan sistem manajemen inventaris menggunakan metode Fishbone. *Jurnal Teknologi dan Manajemen Informatika (JTMI)*, 7(2), 95–102. Retrieved from <http://jurnal.unmer.ac.id/index.php/jtmi>
- [4] Hastriyandi, H., Wahyuni, S., & Syahnaz, E. (2023). Sistem informasi pengelolaan aset barang dan peminjaman peralatan pada laboratorium dan bengkel Politeknik Negeri Sambas berbasis web. *PATANI*, 6(1), 38–44.
- [5] Jollyta, D., & Ramdhan, W. (2020). *Konsep data mining dan penerapan*. Deepublish.
- [6] 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>
- [7] Hasanah, F., Suprpti, 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>
- [8] 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>
- [9] Ardhana, S. R., Widiharhi, 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>
- [10] 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>
- [11] Prihatmono, M. W. ., Arni, S., Iin, J. N. ., & Moeis, D. (2022). Application of the KNN Algorithm for Predicting Data Card Sales at PT. XL Axiata Makassar. *Conference Series*, 4(1), 59–64.
<https://doi.org/10.34306/conference-series.v4i1.692>