

Penerapan Algoritma RANSAC untuk Klasifikasi Kondisi Barang Inventaris pada Disparbud Serdang Bedagai

DOI: <http://dx.doi.org/10.35889/progresif.v22i3.4013>

Creative Commons License 4.0 (CC BY –NC)



Putri Wulandari^{1*}, Raissa Amanda Putri²

Sistem Informasi, Universitas Islam Negeri Sumatera Utara, Medan, Indonesia

*e-mail Corresponding Author. putri.wulndri@gmail.com

Abstract

Inventory condition records at the Tourism and Culture Office (DISPARBUD) of Serdang Bedagai Regency were still managed manually, which caused input errors, duplicate entries, and inconsistent classification of item condition into the Good, Fair, and Severely Damaged categories. This study aimed to apply the Random Sample Consensus (RANSAC) algorithm to classify inventory condition data and to build a web-based classification system supported by a MySQL database. The system was developed using the Waterfall model through requirement analysis, system design with Unified Modeling Language (UML), coding in native PHP, and testing. RANSAC was implemented by repeatedly fitting a model from random samples and retaining the model supported by the largest inlier consensus, thereby separating outliers from valid data. Testing on 728 inventory records produced a classification accuracy of 84.89%, with an average precision of 86.7%, recall of 82.6%, and F1-score of 82.7% across the three condition classes. The system successfully flagged 37 anomalous records for re-verification. These results indicate that RANSAC provided an objective, consistent, and outlier-resistant classification mechanism that supported faster and more accountable inventory reporting at DISPARBUD.

Keywords: RANSAC Algorithm; Inventory Classification; Outlier Detection; Web-Based Information System; MySQL

Abstrak

Pencatatan kondisi barang inventaris pada Dinas Pariwisata dan Kebudayaan (DISPARBUD) Kabupaten Serdang Bedagai masih dilakukan secara manual sehingga menimbulkan kesalahan input, duplikasi data dan penggolongan kondisi barang yang tidak konsisten. Penelitian ini bertujuan menerapkan algoritma *Random Sample Consensus* (RANSAC) untuk mengklasifikasikan data kondisi barang ke dalam kategori Baik, Kurang Baik dan Rusak Berat, serta membangun sistem klasifikasi berbasis web dengan basis data MySQL. Sistem dikembangkan dengan metode *Waterfall*, meliputi analisis kebutuhan, perancangan *Unified Modeling Language* (UML), pengkodean *PHP native* dan pengujian. RANSAC diterapkan dengan membangun model dugaan berulang dari sampel acak dan mempertahankan model yang didukung konsensus *inlier* terbanyak, sehingga memisahkan data pencilaan dari data valid. Pengujian terhadap 728 data inventaris menghasilkan akurasi 84,89%, dengan rata-rata *precision* 86,7%, *recall* 82,6% dan *F1-score* 82,7%, serta menandai 37 data anomali untuk diverifikasi ulang. Hasil ini menunjukkan RANSAC memberikan mekanisme klasifikasi yang objektif, konsisten dan tahan pencilaan, mendukung inventarisasi yang lebih cepat dan akuntabel di DISPARBUD.

Kata Kunci: Algoritma RANSAC; Klasifikasi Inventaris; Deteksi Outlier; Sistem Informasi Berbasis Web; MySQL

1. Pendahuluan

Transformasi digital mendorong instansi pemerintah untuk beralih dari pencatatan manual menuju pengolahan data yang terkomputerisasi, terintegrasi, dan mampu menghasilkan informasi secara cepat dan akurat, terutama dalam pengelolaan aset dan persediaan barang [1].

Sistem informasi inventaris berbasis web dengan basis data terpusat terbukti mempercepat pendataan dan mengurangi duplikasi dibandingkan pencatatan manual yang masih mengandalkan dokumen maupun lembar kerja [2].

Dinas Pariwisata dan Kebudayaan (DISPARBUD) Kabupaten Serdang Bedagai mengelola aset dalam beberapa golongan Kartu Inventaris Barang (KIB A hingga KIB E), Buku Inventaris, dan Kartu Inventaris Ruangan (KIR), yang masing-masing memuat kolom kondisi barang. Pencatatan kondisi barang di instansi ini masih dilakukan secara manual sehingga rawan terhadap kesalahan input, duplikasi data, dan munculnya nilai menyimpang (outlier). Akibatnya, penggolongan kondisi barang ke dalam kategori Baik, Kurang Baik, dan Rusak Berat menjadi tidak konsisten dan sulit dipantau secara cepat oleh pimpinan.

Sejumlah penelitian terdahulu telah mengusulkan model klasifikasi untuk mendukung pengelolaan barang inventaris. Febriana dkk. mengoptimalkan manajemen inventaris pada perusahaan distribusi dengan model klasifikasi ABC-XYZ melalui pendekatan CRISP-DM, mengelompokkan produk berdasarkan kontribusi pendapatan dan stabilitas permintaan dari data penjualan historis [3]. Rahmatuloh dkk. membangun sistem inventaris berbasis web dengan metode *Class-Based Storage* (CBS) yang mengelompokkan barang gudang ke dalam kelas A, B, dan C berdasarkan frekuensi pergerakan untuk merekomendasikan lokasi penyimpanan [4]. Martini dkk. menerapkan algoritma Decision Tree untuk memprediksi kebutuhan pemeliharaan sarana inventaris kampus berdasarkan atribut prioritas, lokasi, kondisi, dan frekuensi penggunaan, dengan akurasi rata-rata 86,67% [5]. Ketiga model tersebut konsisten mengelompokkan barang berdasarkan kriteria ekonomis atau operasional, namun belum menyertakan mekanisme eksplisit untuk menyaring data pencilaan (outlier) akibat kesalahan pencatatan sebelum klasifikasi dilakukan, sehingga data yang menyimpang berpotensi ikut memengaruhi hasil penggolongan akhir. Pada ranah lain, Ikram dan Rohaman membuktikan algoritma RANSAC mampu memisahkan inlier dan outlier secara efektif pada data *Light Detection and Ranging* (LiDAR) berukuran besar [6], namun penerapannya pada data administratif/inventaris pemerintah daerah belum banyak dieksplorasi. Berdasarkan tinjauan tersebut, terdapat kesenjangan (research gap): model-model klasifikasi barang inventaris yang ada belum tahan terhadap pencilaan, sementara algoritma robust seperti RANSAC yang justru unggul menghadapi pencilaan baru terbukti pada domain citra dan geospasial. Kesenjangan inilah yang mendasari kebaruan (novelty) penelitian ini, yaitu menerapkan RANSAC untuk klasifikasi kondisi barang inventaris pada instansi pemerintah, sekaligus sebagai mekanisme deteksi anomali pencatatan yang terintegrasi dalam sistem informasi berbasis web.


Untuk mewujudkan kebaruan tersebut, penelitian ini menerapkan algoritma RANSAC yang bekerja dengan memilih sampel data secara acak berulang kali, membangun model dugaan dari sampel tersebut, kemudian mempertahankan model yang didukung oleh data terbanyak yang sesuai (inlier) dan mengabaikan data pencilaan (outlier) [7]. Keunggulan utama RANSAC terletak pada ketangguhannya terhadap pencilaan, karena tetap menghasilkan estimasi model yang baik meskipun sebagian data terkontaminasi kesalahan, berbeda dengan metode estimasi klasik seperti kuadrat terkecil yang sangat peka terhadap outlier [8]. Pendekatan ini dipilih karena data kondisi barang di DISPARBUD banyak mengandung pencilaan akibat kesalahan input dan duplikasi, sehingga RANSAC dipandang lebih tepat dibandingkan algoritma probabilistik maupun pengelompokan konvensional yang telah dibahas sebelumnya. Penelitian ini bertujuan (1) menerapkan algoritma RANSAC untuk mengklasifikasikan data kondisi barang menjadi kategori Baik, Kurang Baik, dan Rusak Berat; (2) merancang dan membangun sistem klasifikasi berbasis web dengan basis data MySQL; serta (3) mengevaluasi akurasi klasifikasi yang dihasilkan. Penelitian ini diharapkan menghasilkan klasifikasi kondisi barang yang lebih objektif, konsisten, dan tahan terhadap kesalahan pencatatan, sehingga mendukung pengambilan keputusan pemeliharaan dan penghapusan barang sesuai prinsip good governance.

2. Metodologi

Penelitian dilaksanakan di kantor DISPARBUD Kabupaten Serdang Bedagai, yang beralamat di Jalan Tualang, Kecamatan Perbaungan, Sumatera Utara, selama empat bulan dari Maret hingga Juni 2025. Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen terapan yang bertujuan menerapkan dan menguji efektivitas algoritma RANSAC dalam klasifikasi data kondisi barang, sebagaimana pendekatan serupa yang digunakan pada penelitian data mining di lingkungan instansi [9], [6]. Pengumpulan data dilakukan melalui

wawancara dengan staf pengelola barang, observasi langsung terhadap proses pencatatan kondisi barang, serta studi pustaka dari literatur dan penelitian terdahulu yang relevan.

Sistem klasifikasi dikembangkan menggunakan model Waterfall yang terdiri atas lima tahap berurutan, yaitu analisis kebutuhan sistem, desain sistem, pengembangan sistem, pengujian, dan penerapan sistem. Tahap analisis kebutuhan dilakukan melalui studi literatur dan kajian mendalam terhadap data inventaris DISPARBUD. Tahap desain merancang basis data, antarmuka pengguna, dan alur algoritma menggunakan pemodelan UML (use case diagram dan class diagram). Tahap pengembangan membangun sistem berbasis PHP native, basis data MySQL, dan antarmuka AdminLTE 3 dengan Bootstrap 4 serta DataTables, termasuk menanamkan algoritma RANSAC sebagai inti pengolahan data. Tahap pengujian mengevaluasi fungsionalitas sistem dan hasil klasifikasi, dilanjutkan tahap penerapan pada pengguna. Kerangka berpikir penelitian yang menghubungkan permasalahan lapangan dengan solusi RANSAC ditunjukkan pada Gambar 1.



Gambar 1. Kerangka Berpikir Penelitian

2.1 Variabel-variabel Klasifikasi

Data yang digunakan bersumber dari data barang inventaris DISPARBUD Kabupaten Serdang Bedagai yang tercatat dalam Buku Inventaris dan Kartu Inventaris Barang (KIB), meliputi atribut nama/jenis barang, tahun perolehan, nilai perolehan, dan kondisi barang hasil pencatatan petugas pengelola barang. Setelah proses seleksi data, diperoleh dataset akhir sebanyak 728 rekaman barang yang digunakan sebagai basis pembentukan model dan evaluasi klasifikasi.

Dalam penerapan algoritma RANSAC, atribut-atribut tersebut diringkas menjadi dua variabel klasifikasi utama, yaitu variabel input/proses (X) dan variabel target (Y). Variabel input/proses (X) adalah usia barang, dihitung dari selisih antara tahun berjalan dan tahun perolehan barang, kemudian dinormalisasi ke rentang [0,1] menggunakan normalisasi min-max sebagaimana Persamaan (1), agar rentang usia barang yang bervariasi tidak mendominasi proses pembentukan model garis:


$$X_{\text{norm}} = (X - X_{\text{min}}) / (X_{\text{max}} - X_{\text{min}}) \quad (1)$$

Variabel target (Y) adalah skor kondisi barang, yaitu hasil konversi dari label kategorikal kondisi aktual (Baik, Kurang Baik, Rusak Berat) yang dicatat petugas menjadi nilai numerik: Baik = 2, Kurang Baik = 1, dan Rusak Berat = 0. Variabel Y berperan ganda: sebagai variabel

dependen dalam pembentukan model regresi robust RANSAC, sekaligus sebagai label ground truth yang dibandingkan dengan hasil prediksi sistem pada tahap evaluasi akurasi. Nilai perolehan dan jenis barang tidak dilibatkan langsung sebagai variabel numerik dalam model RANSAC, namun tetap disimpan sebagai atribut deskriptif pada antarmuka sistem untuk mendukung verifikasi oleh petugas.

2.2 Algoritma RANSAC

Algoritma RANSAC diterapkan melalui lima tahapan utama, yaitu pembentukan model, perhitungan residual atau galat, penentuan inlier dan outlier, pengulangan iterasi, dan pemilihan model terbaik. Alur lengkap tahapan ini ditunjukkan pada Gambar 2.



Gambar 2. Flowchart Algoritma RANSAC

Pembentukan model dilakukan dengan memilih secara acak sejumlah s titik data minimum dari keseluruhan dataset, kemudian membentuk model garis dugaan $Y = mX + b$ dari titik-titik tersebut. Untuk model garis lurus, jumlah titik minimum yang dibutuhkan adalah $s = 2$, sesuai derajat kebebasan persamaan garis.

Setiap titik data selanjutnya diuji terhadap model dugaan dengan menghitung residual atau galat (error), yaitu selisih absolut antara nilai Y aktual dan nilai Y hasil prediksi model, sebagaimana Persamaan (2):

$$error_i = |Y_i(\text{aktual}) - Y_i(\text{prediksi})| \quad (2)$$

Suatu data dinyatakan sebagai inlier apabila $error_i \leq t$, dengan t adalah ambang batas galat (threshold/error tolerance) yang ditetapkan sebesar 0,5 berdasarkan hasil pengujian empiris pada sistem; sebaliknya, data dengan $error_i > t$ dinyatakan sebagai outlier atau pencila yang memerlukan verifikasi ulang.

Proses pembentukan model dan pengujian inlier/outlier tersebut diulang sebanyak N iterasi. Banyaknya iterasi minimum yang diperlukan agar terdapat peluang p untuk memperoleh setidaknya satu sampel yang seluruhnya berisi inlier dihitung menggunakan formula estimasi iterasi RANSAC [7] pada Persamaan (3):

$$N = \log(1 - p) / \log(1 - w^s) \quad (3)$$

dengan p adalah tingkat keyakinan yang ditetapkan sebesar 0,99 dan w adalah proporsi inlier yang diasumsikan sebesar 0,70. Berdasarkan Persamaan (3) dengan $s = 2$, diperoleh N minimum secara teoretis sebesar 7 iterasi. Namun demi keandalan hasil pada dataset yang berukuran

relatif besar, sistem menetapkan batas bawah 20 iterasi dan batas atas 100 iterasi, sehingga jumlah iterasi yang benar-benar dijalankan pada setiap proses klasifikasi adalah 20 kali.

Pemilihan model terbaik dilakukan dengan memilih model yang memiliki jumlah inlier (consensus set) terbanyak di antara seluruh iterasi yang dijalankan. Model dengan consensus set terbesar tersebut selanjutnya disempurnakan (refined) melalui regresi kuadrat terkecil (least squares) menggunakan seluruh titik inlier — bukan hanya s titik sampel awal — sehingga diperoleh model garis akhir yang lebih presisi sebagai representasi hubungan antara usia dan kondisi barang.

Model akhir tersebut digunakan untuk menentukan kelas kondisi barang melalui dua tahap. Pertama, nilai Y diprediksi untuk setiap barang berdasarkan nilai X (usia ternormalisasi) menggunakan persamaan model akhir. Kedua, nilai Y prediksi tersebut dipetakan kembali menjadi kelas kategorikal melalui ambang skor pada Persamaan (4)–(6), yang ditetapkan pada titik tengah antar skor kondisi (2, 1, dan 0):

$$\begin{aligned} \text{Kelas} &= \text{Baik, jika } Y_{\text{prediksi}} \geq 1,5 \quad (4) \\ \text{Kelas} &= \text{Kurang Baik, jika } 0,5 \leq Y_{\text{prediksi}} < 1,5 \quad (5) \\ \text{Kelas} &= \text{Rusak Berat, jika } Y_{\text{prediksi}} < 0,5 \quad (6) \end{aligned}$$

Barang yang teridentifikasi sebagai outlier pada tahap konsensus RANSAC tetap diklasifikasikan menggunakan aturan pemetaan yang sama pada Persamaan (4)–(6), namun ditandai secara khusus pada sistem sebagai data yang memerlukan verifikasi ulang oleh petugas, karena kondisi tercatatnya menyimpang dari pola umum hubungan usia dan kondisi barang yang direpresentasikan oleh model akhir.

2.3 Pembagian Data

Berbeda dengan algoritma klasifikasi terawasi (*supervised learning*) pada umumnya yang memerlukan pembagian data latih (training set), data validasi (*validation set*), dan data uji (testing set) secara terpisah, RANSAC bekerja sebagai algoritma estimasi robust (*robust estimation*) yang membentuk model dari sampel acak minimal di dalam dataset itu sendiri, tanpa fase pelatihan terawasi yang terpisah dari data evaluasi.

Pada penelitian ini, seluruh 728 data barang digunakan sebagai satu kesatuan: proses pengambilan sampel acak $s = 2$ titik pada setiap iterasi RANSAC berperan sebagai mekanisme pembentukan model internal (analog dengan fase pelatihan), sedangkan seluruh 728 data yang sama juga berperan sebagai data uji (*testing set*) yang hasil klasifikasinya dibandingkan terhadap label kondisi aktual hasil verifikasi lapangan oleh petugas pengelola barang. Dengan demikian, rasio pembagian data pada penelitian ini dapat dinyatakan sebagai 100% data digunakan untuk pengujian, tanpa pembagian data validation terpisah, karena RANSAC tidak memiliki parameter yang dilatih secara iteratif terhadap fungsi kerugian (*loss function*) sebagaimana pada model pembelajaran mesin terawasi lainnya. Pendekatan pembagian data satu kesatuan ini menjadi salah satu keterbatasan metodologis yang dibahas lebih lanjut pada bagian Pembahasan.

2.4 Skenario Pengujian dan Metrik Evaluasi

Pengujian dilakukan dengan menjalankan algoritma RANSAC terhadap keseluruhan 728 data menggunakan nilai acak (*random seed*) yang ditetapkan secara tetap (*fixed seed*), sehingga proses pengambilan sampel acak pada setiap iterasi menghasilkan luaran yang konsisten dan dapat direproduksi pada setiap kali sistem dijalankan — sebuah pertimbangan penting mengingat RANSAC secara inheren bersifat stokastik. Hasil klasifikasi (kelas prediksi RANSAC) untuk setiap barang kemudian dibandingkan dengan kelas aktual hasil verifikasi lapangan, dan disusun ke dalam confusion matrix berukuran 3×3 yang memetakan tiga kelas kondisi (Baik, Kurang Baik, Rusak Berat).

Metrik evaluasi performa yang digunakan meliputi akurasi keseluruhan (Persamaan (7)), serta precision, recall, dan F1-score untuk masing-masing kelas kondisi (Persamaan (8)–(10)):

$$\text{Akurasi} = (TP^{\text{Baik}} + TP^{\text{KB}} + TP^{\text{RB}}) / \text{Total} \quad (7)$$

$$\text{Precision} = TP / (TP + FP) \quad (8)$$

$$\text{Recall} = TP / (TP + FN) \quad (9)$$

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

dengan TP merupakan angka pada diagonal utama confusion matrix, FP adalah jumlah data lain dalam kolom prediksi yang sama (selain diagonal), dan FN adalah jumlah data lain dalam baris aktual yang sama (selain diagonal). Selain metrik klasifikasi tersebut, jumlah dan persentase data yang teridentifikasi sebagai outlier turut dilaporkan sebagai indikator tambahan untuk menilai kemampuan RANSAC dalam menyaring anomali pencatatan, mengingat kemampuan ini merupakan kontribusi utama yang membedakan RANSAC dari algoritma klasifikasi konvensional yang tidak memiliki mekanisme penapisan pencilan secara eksplisit.

3. Hasil dan Pembahasan

3.1 Karakteristik Dataset

Dataset yang digunakan dalam penelitian ini berjumlah 728 data barang inventaris DISPARBUD Kabupaten Serdang Bedagai, bersumber dari Buku Inventaris dan Kartu Inventaris Barang (KIB). Setiap rekaman memuat atribut nama/jenis barang, tahun perolehan, nilai perolehan, dan kondisi barang aktual hasil pencatatan dan verifikasi lapangan oleh petugas pengelola barang.

Tabel 1 menyajikan ilustrasi format dan struktur data yang diolah, berupa usia barang hasil perhitungan (X), skor kondisi hasil konversi (Y), dan label kondisi aktual. Nilai pada Tabel 1 merupakan ilustrasi format data untuk menggambarkan struktur atribut yang diproses sistem, bukan cuplikan data barang yang sebenarnya.

Tabel 1. Ilustrasi Struktur Data Barang

No	Usia Barang (Tahun)	Skor Kondisi (Y)	Kondisi Aktual
1	3	2	Baik
2	6	2	Baik
3	10	1	Kurang Baik
4	13	1	Kurang Baik
5	19	0	Rusak Berat

Distribusi kelas kondisi aktual pada dataset menunjukkan komposisi yang tidak seimbang (imbalanced) antar kelas, sebagaimana disajikan pada Tabel 2: kelas Baik berjumlah 426 data (58,5%), Kurang Baik berjumlah 187 data (25,7%), dan Rusak Berat berjumlah 115 data (15,8%) dari total 728 data. Ketidakeimbangan ini konsisten dengan karakteristik umum aset pemerintah, di mana sebagian besar barang masih berada dalam kondisi layak pakai, sementara barang dengan kerusakan berat berjumlah relatif lebih sedikit.

Tabel 2. Distribusi Kelas Kondisi Aktual

Kelas Kondisi	Jumlah Data	Persentase
Baik	426	58,5%
Kurang Baik	187	25,7%
Rusak Berat	115	15,8%
Total	728	100%

3.2 Hasil Preprocessing

Tahap preprocessing mengubah data mentah menjadi dua variabel numerik siap pakai sebagaimana dijelaskan pada sub-bab 2.1. Label kondisi kategorikal (Baik, Kurang Baik, Rusak Berat) berhasil dikonversi seluruhnya menjadi skor numerik Y tanpa nilai yang hilang (missing value), karena setiap rekaman pada dataset akhir telah melalui proses pembersihan data pada tahap pengumpulan. Usia barang (X) dihitung dari selisih tahun berjalan dan tahun perolehan, menghasilkan rentang usia yang bervariasi mulai dari barang yang baru diperoleh hingga barang berusia puluhan tahun, kemudian dinormalisasi ke rentang [0,1] menggunakan Persamaan (1) agar seluruh nilai X berada pada skala yang seragam sebelum diproses oleh algoritma RANSAC. Hasil normalisasi ini penting agar proses pembentukan model garis tidak bias terhadap barang dengan usia absolut yang jauh lebih besar dibandingkan barang lain.

3.3 Hasil Penerapan RANSAC

Algoritma RANSAC dijalankan terhadap 728 data dengan parameter ambang batas galat $t = 0,5$ dan jumlah iterasi $N = 20$, sebagaimana ditetapkan pada sub-bab 2.2. Proses iteratif menghasilkan model garis akhir setelah penyempurnaan (refinement) menggunakan seluruh titik inlier, dengan persamaan:

$$Y = -2,3864X + 2,2990 \quad (11)$$

Berdasarkan model tersebut, sistem berhasil mengidentifikasi 691 data (94,9%) sebagai inlier — yaitu data yang polanya konsisten dengan hubungan antara usia dan kondisi barang — dan 37 data (5,08%) sebagai outlier yang menyimpang dari pola tersebut dan ditandai untuk verifikasi ulang. Merujuk pada Persamaan (4)–(6), model akhir ini secara empiris berkorespondensi dengan rentang usia barang berikut: barang berusia ≤ 7 tahun cenderung terklasifikasi Baik, barang berusia 8–14 tahun cenderung terklasifikasi Kurang Baik, dan barang berusia ≥ 15 tahun cenderung terklasifikasi Rusak Berat. Pemetaan usia-ke-kelas ini konsisten dengan pola kerusakan aset fisik pada umumnya, yang cenderung memburuk seiring bertambahnya usia pemakaian.

3.4 Confusion Matrix dan Hasil Evaluasi Performa

Penerapan algoritma RANSAC terhadap 728 data inventaris DISPARBUD menghasilkan penggolongan kondisi barang ke dalam kategori Baik, Kurang Baik, dan Rusak Berat, sedangkan data yang tidak sesuai model dipisahkan sebagai outlier. Perbandingan hasil klasifikasi RANSAC terhadap kondisi aktual (data hasil verifikasi lapangan) disajikan dalam bentuk confusion matrix pada Tabel 3.

Tabel 3. Confusion Matrix Hasil Klasifikasi Kondisi Barang

Aktual \ Prediksi	Baik	Kurang Baik	Rusak Berat	Total
Baik	363	63	0	426
Kurang Baik	9	177	1	187
Rusak Berat	6	31	78	115
Total	378	271	79	728

Nilai pada diagonal utama Tabel 3 (363, 177, dan 78) merupakan jumlah prediksi yang sesuai dengan kondisi aktual untuk setiap kelas. Berdasarkan Persamaan (7),

$$\text{Akurasi} = (\text{TP}_B + \text{TP}_{KB} + \text{TP}_{RB}) / \text{Total Data} = (363 + 177 + 78) / 728 = 618 / 728 \approx 0,85 \quad (84,89\%)$$

Berdasarkan perhitungan tersebut, algoritma RANSAC menghasilkan akurasi sebesar 84,89%. Nilai precision, recall, dan F1-score untuk masing-masing kelas kondisi ditunjukkan pada Tabel 4.

Perhitungan precision, recall, dan F1-score mengacu pada Persamaan (8)–(10) pada sub-bab 2.4.

Keterangan :

TP = angka pada diagonal utama confusion matrix.

FP = jumlah angka lain dalam kolom yang sama (selain diagonal).

FN (False Negative) = jumlah angka lain dalam baris yang sama (selain diagonal).

Tabel 4. Hasil Evaluasi per Kelas Kondisi Barang

Kelas Kondisi	Precision	Recall	F1-Score
Baik	96%	85,2%	90,3%
Kurang Baik	65,3%	94,7%	77,3%
Rusak Berat	98,7%	67,8%	80,4%
Rata-rata	86,7%	82,6%	82,7%

Rata-rata *precision*, *recall*, dan F1-score berada di atas 80%, menunjukkan bahwa algoritma RANSAC bekerja baik pada seluruh kelas kondisi. Kesalahan klasifikasi terbesar terjadi pada perbedaan antara kelas Baik dan Kurang Baik karena kedua kelas memiliki ciri atribut yang berdekatan, sedangkan kelas Rusak Berat paling mudah dikenali karena perbedaan atributnya yang mencolok. Selain 728 data yang berhasil digolongkan, sistem juga mengidentifikasi 37 data (5,08%) sebagai outlier atau anomali pencatatan yang memerlukan verifikasi ulang oleh petugas, sebagaimana data (100, 5) pada ilustrasi numerik algoritma yang jelas menyimpang dari pola data lain akibat kesalahan input.


3.5 Implementasi pada Sistem Aplikasi

Sistem klasifikasi kondisi barang diimplementasikan sebagai aplikasi web menggunakan PHP native, basis data MySQL, dan antarmuka AdminLTE 3 dengan Bootstrap 4. Gambar 3 menampilkan halaman dashboard yang memuat kartu statistik total barang beserta distribusi kondisi, grafik donut interaktif, dan panel status klasifikasi RANSAC yang menyajikan akurasi terakhir.




Gambar 3. Tampilan Dashboard Sistem

Proses klasifikasi dijalankan melalui halaman khusus yang memungkinkan pengguna mengatur parameter ambang batas t dan jumlah maksimal iterasi N , sebagaimana ditunjukkan pada Gambar 4. Sistem menampilkan ringkasan hasil (jumlah inlier, outlier, dan iterasi yang digunakan) beserta nilai galat setiap data secara langsung tanpa memuat ulang halaman.



Gambar 4. Tampilan Proses Klasifikasi RANSAC

Hasil dan evaluasi klasifikasi disajikan pada halaman tersendiri (Gambar 5) yang memuat kartu statistik akurasi, *confusion matrix* interaktif dengan diagonal utama yang disorot, tabel evaluasi per kelas kondisi, serta grafik perbandingan kondisi aktual terhadap hasil prediksi RANSAC.



Gambar 5. Tampilan Hasil dan Evaluasi RANSAC

3.6 Pembahasan

Hasil pengujian pada Tabel 3 dan Tabel 4 menunjukkan bahwa penelitian ini menjawab ketiga tujuan pada Pendahuluan. Tujuan pertama tercapai melalui mekanisme konsensus RANSAC (sub-bab 2.2 dan 3.3). Tujuan kedua tercapai melalui sistem klasifikasi berbasis web dengan basis data MySQL (sub-bab 3.5), dengan RANSAC tertanam sebagai inti pengolahan data. Tujuan ketiga tercapai melalui pengujian (sub-bab 3.4) yang menghasilkan akurasi 84,89%, rata-rata precision 86,7%, recall 82,6%, dan F1-score 82,7%. Capaian ini menunjukkan bahwa masalah inti berupa kesalahan input dan ketidakkonsistenan penggolongan kondisi barang telah terjawab melalui mekanisme konsensus yang menyaring data pencilan sebelum memengaruhi hasil penggolongan kelas lain.

Temuan empiris ini selaras dengan konsep ilmiah yang menjadi landasan metode, sebagaimana diulas pada survei RANSAC terkini [7] dan generalisasinya melalui MLESAC [8]: RANSAC tetap menghasilkan estimasi model yang baik selama proporsi inlier cukup tinggi. Proporsi inlier 94,9% (691/728) pada penelitian ini jauh melampaui asumsi $w = 0,70$ pada Persamaan (3), sehingga $N = 20$ iterasi yang dijalankan sudah lebih dari cukup dibanding syarat minimum teoretis 7 iterasi [7]. Kesesuaian ini memperkuat validitas RANSAC pada domain data administratif, berbeda dari domain visi komputer tempat algoritma ini dikembangkan. Di sisi lain, ambang batas $t = 0,5$ masih ditentukan secara empiris, sejalan dengan keterbatasan yang diidentifikasi Bai dkk. [10] bahwa keandalan RANSAC konvensional bergantung pada threshold manual, bukan adaptif terhadap karakteristik data.

Dibandingkan penelitian terdahulu tentang model klasifikasi barang inventaris, hasil ini menunjukkan pola dukungan sekaligus perbedaan. Penelitian ini mendukung temuan Martini dkk. [5] bahwa atribut kondisi dan penggunaan barang adalah prediktor andal untuk kebutuhan pemeliharaan aset, dengan akurasi sebanding (84,89% berbanding 86,67% pada Decision Tree), bedanya, RANSAC menyaring data pencilan secara eksplisit, mekanisme yang tidak dimiliki Decision Tree. Penelitian ini juga berbeda pendekatan dari Febriana dkk. [3] dan Rahmatuloh dkk. [4] yang mengklasifikasikan barang berdasarkan kriteria ekonomis dan operasional; penelitian ini memperluas cakupan model klasifikasi inventaris dengan menambahkan dimensi kondisi fisik barang. Mekanisme konsensus RANSAC yang menyaring 37 data anomali juga tidak dimiliki pendekatan probabilistik Naïve Bayes [11] maupun K-Medoids [12], karena keduanya tidak secara eksplisit memisahkan pencilan sebelum penggolongan akhir. Temuan akurasi dan proporsi inlier 94,9% turut memperkuat hasil Ikram dan Rohaman [6] pada data LiDAR, menunjukkan keandalan RANSAC yang konsisten meski diterapkan pada ranah yang sama sekali berbeda — sebuah temuan baru yang memperluas generalisasinya di luar domain citra dan geospasial. Dibandingkan sistem informasi inventaris sebelumnya yang umumnya berhenti pada otomasi pencatatan [2], [13], [14], kebaruan penelitian ini terletak pada penyertaan mekanisme penapisan pencilan dalam alur klasifikasi.

Temuan ini berkontribusi bagi pengembangan ilmu pengetahuan pada bidang sistem informasi manajemen aset pemerintah dalam dua aspek. Pertama, secara metodologis, penelitian ini memperkaya aset model klasifikasi barang inventaris dengan pendekatan estimasi robust yang sebelumnya terbatas pada pengolahan citra dan geospasial, sekaligus menutup kesenjangan penelitian yang diidentifikasi pada Pendahuluan. Kedua, secara praktis, sistem ini mendukung prinsip good governance dalam pengelolaan Barang Milik Daerah, khususnya

akuntabilitas dan transparansi data kondisi aset. Sebagaimana ditekankan Alfian dkk. [15], kejelasan informasi kondisi barang adalah faktor penentu tata kelola aset yang akuntabel; mekanisme penapisan otomatis penelitian ini berkontribusi langsung pada aspek tersebut, sekaligus menjadi preseden metodologis bagi sistem informasi pemerintahan lain yang menghadapi masalah serupa.

Beberapa keterbatasan perlu dicatat sebagai peluang penelitian lanjutan. Pertama, pengujian akurasi baru dilakukan pada satu golongan KIB, sehingga generalisasi ke seluruh golongan KIB A–E memerlukan pengujian lanjutan pada dataset lebih luas. Kedua, sebagaimana diuraikan pada sub-bab 2.3, penelitian ini tidak menerapkan pembagian data latih/validasi/uji terpisah; penelitian selanjutnya dapat mengadopsi skema *cross-validation* seperti Tuntun dkk. [16] untuk memperoleh estimasi generalisasi yang lebih teruji. Ketiga, ambang batas t dan iterasi N masih ditentukan secara manual; merujuk pendekatan *adaptive threshold* Bai dkk. [10], penelitian selanjutnya dapat mengeksplorasi penalaan ambang batas otomatis. Keempat, perbandingan langsung RANSAC dengan algoritma lain seperti *Naïve Bayes*, *K-Nearest Neighbor*, atau *Decision Tree* pada dataset identik belum dilakukan, sehingga keunggulan relatif RANSAC belum terukur secara komparatif.

4. Simpulan

Penelitian ini berhasil menerapkan algoritma RANSAC untuk mengklasifikasikan data kondisi barang pada DISPARBUD Kabupaten Serdang Bedagai ke dalam kategori Baik, Kurang Baik, dan Rusak Berat, dengan cara membangun model dugaan dari sampel acak dan mempertahankan model yang didukung oleh inlier terbanyak sehingga penggolongan menjadi lebih tahan terhadap pencilan. Sistem klasifikasi berbasis web dengan basis data MySQL yang dirancang menggunakan pemodelan UML dan dikembangkan dengan model Waterfall berhasil menanamkan algoritma RANSAC sebagai inti pengolahan data, serta menyediakan antarmuka bagi petugas untuk memantau kondisi, hasil klasifikasi, dan data outlier secara langsung. Pengujian terhadap 728 data inventaris menunjukkan akurasi klasifikasi sebesar 84,89% dengan rata-rata *precision* 86,7%, *recall* 82,6%, dan *F1-score* 82,7%, serta berhasil menandai 37 data sebagai anomali pencatatan yang memerlukan verifikasi ulang. Hasil ini membuktikan bahwa RANSAC efektif menghasilkan klasifikasi kondisi barang yang lebih objektif, konsisten, dan akuntabel, sehingga dapat mendukung DISPARBUD dalam mempercepat inventarisasi serta pengambilan keputusan pemeliharaan dan penghapusan aset sesuai prinsip *good governance*. Penelitian selanjutnya disarankan membandingkan kinerja RANSAC dengan algoritma klasifikasi lain seperti *Naïve Bayes*, *K-Nearest Neighbor*, atau *Decision Tree*, memperluas pengujian pada seluruh golongan KIB, mengadopsi skema *cross-validation* untuk memperoleh estimasi generalisasi yang lebih teruji mengingat penelitian ini belum menerapkan pembagian data latih, validasi, dan uji secara terpisah, serta mengeksplorasi metode penalaan parameter ambang batas dan iterasi secara otomatis agar hasil klasifikasi semakin representatif.

Daftar Referensi

- [1] M. Alda, "Sistem Informasi Pengolahan Data Kependudukan pada Kantor Desa Sampean Berbasis Android," *J. Media Inform. Budidarma*, vol. 4, no. 1, pp. 1–8, 2020.
- [2] M. Usnaini, V. Yasin, and A. Z. Sianipar, "Perancangan Sistem Informasi Inventarisasi Aset Berbasis Web Menggunakan Metode Waterfall," *J. Manaj. Inform. Jayakarta*, vol. 1, no. 1, pp. 36–55, 2021.
- [3] A. Febriana, A. Bachtiar, E. Haryanto, and Indriaturrahmi, "Optimalisasi Sistem Manajemen Inventory Melalui Klasifikasi Produk Menggunakan ABC-XYZ Classification Model," *J. Inform. Teknol. dan Sains (JINTEKS)*, vol. 7, no. 1, pp. 336–345, 2025.
- [4] M. Rahmatuloh, W. Resdiana, and F. A. Fadillah, "Rancang Bangun Sistem Inventory Berbasis Web dengan Metode Class Based Storage (Studi Kasus pada Bandara Husein Sastranegara)," *J. Tek. Inform.*, vol. 17, no. 2, pp. 91–97, 2025.
- [5] Martini, N. Agustina, and E. Sutinah, "Penerapan Algoritma Decision Tree untuk Memprediksi Pengelolaan Inventaris Sarana Pembelajaran Kampus," *Bull. Comput. Sci. Res.*, vol. 6, no. 1, pp. 426–433, 2025.
- [6] Ikram and M. Rohaman, "Analisis Kemampuan Algoritma Random Sample Consensus (RANSAC) untuk Klasifikasi Ground pada Data Light Detection and Ranging (LiDAR)," *Geoid*, vol. 19, no. 1, pp. 58–72, 2023.

- [7] J. M. Martínez-Otzeta, I. Rodríguez-Moreno, I. Mendialdua, and B. Sierra, "RANSAC for Robotic Applications: A Survey," *Sensors*, vol. 23, no. 1, p. 327, 2023.
- [8] P. H. S. Torr and A. Zisserman, "MLESAC: A New Robust Estimator with Application to Estimating Image Geometry," *Comput. Vis. Image Underst.*, vol. 78, no. 1, pp. 138–156, 2000.
- [9] Triase and Samsudin, "Implementasi Data Mining dalam Mengklasifikasikan UKT (Uang Kuliah Tunggal) pada UIN Sumatera Utara Medan," *J. Teknol. Inf.*, vol. 4, no. 2, pp. 370–376, 2020.
- [10] J. Bai, D. Qin, L. Ma, and M. B. Teklu, "An Improved RANSAC Algorithm Based on Adaptive Threshold for Indoor Positioning," *Mobile Inf. Syst.*, vol. 2021, Art. no. 2952977, 2021.
- [11] F. D. Pratama, I. Zufria, and Triase, "Implementasi Data Mining Menggunakan Algoritma Naïve Bayes untuk Klasifikasi Penerima Program Indonesia Pintar," *Rabit: J. Teknol. dan Sist. Inf. Univrab*, vol. 7, no. 1, pp. 77–84, 2022.
- [12] W. S. Wanda, R. A. Putri, and H. Santoso, "Implementasi Algoritma K-Medoids pada Sistem Informasi Pengelompokan Wilayah Kemiskinan di Provinsi Sumatera Utara Berbasis Web," *J. Komput. Teknol. Inf. Sist. Inf. (JUKTISI)*, vol. 4, no. 2, pp. 469–479, 2025.
- [13] J. S. Pasaribu, "Perancangan Sistem Informasi Berbasis Web Pengelolaan Inventaris Aset Kantor di PT. MPM Finance Bandung," *J. Ilm. Teknol. Inf. Terapan (JITTER)*, vol. 7, no. 3, pp. 187–196, 2021.
- [14] N. Safitri, H. Afriyadi, and M. Yusuf, "Perancangan Sistem Informasi Aplikasi Inventaris Barang Habis Pakai Berbasis Website pada Badan Pengelola Pajak dan Retribusi Daerah Kota Jambi Menggunakan Metode Waterfall," *J. Komput. Teknol. Inf. Sist. Inf. (JUKTISI)*, vol. 4, no. 2, pp. 955–963, 2025.
- [15] Alfian, H. T. RFS, and Z. Rusli, "Implementasi Prinsip Good Governance Aset Negara," *J. Kebijakan Publik*, vol. 14, no. 2, pp. 227–232, 2023.
- [16] R. Tuntun, K. Kusrini, and K. Kusnawi, "Analisis Perbandingan Kinerja Algoritma Klasifikasi dengan Menggunakan Metode K-Fold Cross Validation," *J. Media Inform. Budidarma*, vol. 6, no. 4, pp. 2111–2119, 2022.
- [17] A. Putri, Suparti, and R. Rahmawati, "Klasifikasi Menggunakan Metode Data Mining," *J. Gaussian*, vol. 8, no. 1, pp. 1–10, 2019.
- [18] Suendri, "Implementasi Diagram UML (Unified Modelling Language) pada Perancangan Sistem Informasi Remunerasi Dosen dengan Database Oracle (Studi Kasus: UIN Sumatera Utara Medan)," *Algoritma: J. Ilmu Komput. dan Inform.*, vol. 3, no. 1, pp. 1–9, 2018.
- [19] S. Kartika, Suendri, and R. A. Putri, "Sistem Pencarian Lokasi dan Rute Terdekat Menggunakan Metode Haversine Formula pada Aplikasi Donatur Pakaian Berbasis Android," *Al-Ulum: J. Sains dan Teknol.*, vol. 7, no. 1, pp. 14–20, 2021.
- [20] A. Nugraha and D. Rosmeida, *Perancangan Sistem Informasi Berorientasi Objek Menggunakan Unified Modeling Language*. Bandung: Informatika, 2021.
- [21] M. Arhami and M. Nasir, *Data Mining – Algoritma dan Implementasi*. Yogyakarta: Penerbit Andi, 2020.