



**PENERAPAN DATA MINING UNTUK KLASIFIKASI
KONDISI INVENTARIS NONMEDIS MENGGUNAKAN
RANDOM FOREST DAN SMOTE SEBAGAI PENDUKUNG
EFISIENSI MANAJEMEN DI RSD DR. SOEBANDI**

*Diajukan untuk memenuhi sebagian persyaratan memperoleh gelar Sarjana pada
program studi Sistem Informasi*

SKRIPSI

Oleh:

Akmal Ihab Syauqi

222410101034

**KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET, DAN
TEKNOLOGI**

UNIVERSITAS JEMBER

FAKULTAS ILMU KOMPUTER

PROGRAM STUDI SISTEM INFORMASI

JEMBER

2026



**PENERAPAN DATA MINING UNTUK KLASIFIKASI
KONDISI INVENTARIS NONMEDIS MENGGUNAKAN
RANDOM FOREST DAN SMOTE SEBAGAI PENDUKUNG
EFISIENSI MANAJEMEN DI RSD DR. SOEBANDI**

*Diajukan untuk memenuhi sebagian persyaratan memperoleh gelar Sarjana pada
program studi Sistem Informasi*

SKRIPSI

Oleh:

Akmal Ihab Syauqi

222410101034

**KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET, DAN
TEKNOLOGI**

UNIVERSITAS JEMBER

FAKULTAS ILMU KOMPUTER

PROGRAM STUDI SISTEM INFORMASI

JEMBER

2026

PERSEMBAHAN

Puji syukur penulis panjatkan atas karunia dan nikmat yang telah diberikan oleh Allah SWT. Sholawat serta salam selalu tercurahkan kepada Nabi Muhammad SAW. Penulis persembahkan ucapan terima kasih atas terselesaikannya skripsi ini kepada:

1. Kedua orang tua saya, Mohammad Shodikin dan Nurul Kamariyah yang senantiasa mendoakan, memberikan arahan, motivasi, serta penguat di setiap perjalanan hidup hingga penulis mampu menyelesaikan studinya sampai meraih gelar sarjana;
2. Saudara-saudara saya, Diinar Athika Firdaus yang selalu menyayangi, mendukung, serta memberikan saran-saran positif. Tidak lupa kakak ipar saya, Firman Zakaria yang juga selalu mendukung saya;
3. Ibu Khoirunnisa” Afandi M.Kom. selaku Dosen Pembimbing yang senantiasa meluangkan waktu dalam memberikan pengarahan dan bimbingan hingga terselesaikannya penulisan skripsi saya;
4. Bapak Fajrin Nurman Arifin, ST., M.Eng. selaku Dosen Penguji Utama dan Ibu Gayatri Dwi Santika, S.SI., M.Kom. selaku Dosen Penguji Anggota yang telah memberikan kritik dan saran membangun dalam penyempurnaan skripsi saya;
5. Kekasih saya, Kamilah Pascayuna Nurmalika yang sudah menemani saya dalam proses pengerjaan skripsi ini, meluangkan waktu, tenaga, dan pikiran dalam membantu serta memotivasi saya menyelesaikan skripsi saya;
6. Sahabat-sahabat saya dalam grup “UAS Etprof Berbagi Mechanical Keyboard TFT Programmer”, Muhammad Fa’iq Ammar, Haikal Nuril Abiyit, dan Muhammad Afif Rohman Muzaky yang selalu mendukung saya dan menemani di masa perkuliahan dari zaman mahasiswa baru hingga saat ini;
7. Keluarga besar Himpunan Mahasiswa Sistem Informasi, terutama teman-teman saya HIMASIF angkatan 2022 serta kakak dan adik saya di Divisi Humas dan Divisi Mediatek. HIMASIF telah menjadi wadah saya berkembang dan memberikan pengalaman yang berarti selama berorganisasi.

MOTTO

“One truth prevails.”

– Shinichi Kudo



PERNYATAAN ORISINALITAS

Saya yang bertanda tangan di bawah ini :

Nama : Akmal Ihab Syauqi

NIM : 222410101034

Menyatakan dengan sesungguhnya bahwa skripsi yang berjudul: *Penerapan Data Mining untuk Klasifikasi Kondisi Inventaris Nonmedis menggunakan Random Forest dan SMOTE sebagai Pendukung Efisiensi Manajemen di RSD dr. Soebandi.*

Adalah benar-benar hasil karya sendiri, kecuali jika dalam pengutipan substansi disebutkan sumbernya, dan belum pernah diajukan pada institusi mana pun, serta bukan karya jiplakan. Saya bertanggung jawab atas keabsahan dan kebenaran isinya sesuai dengan sikap ilmiah yang harus dijunjung tinggi.

Demikian pernyataan ini saya buat dengan sebenarnya, tanpa adanya tekanan dan paksaan dari pihak mana pun serta bersedia mendapat sanksi akademik jika ternyata di kemudian hari pernyataan ini tidak benar.

Jember, 16 Juli 2026

Yang menyatakan,



Akmal Ihab Syauqi

NIM 222410101034

HALAMAN PERSETUJUAN

Skripsi berjudul *Penerapan Data Mining untuk Klasifikasi Kondisi Inventaris Nonmedis menggunakan Random Forest dan SMOTE sebagai Pendukung Efisiensi Manajemen di RSD Dr. Soebandi* telah diuji dan disetujui oleh Fakultas Ilmu Komputer Universitas Jember pada:

Hari : Kamis
Tanggal : 16 Juli 2026
Tempat : Fakultas Ilmu Komputer Universitas Jember

Pembimbing

Tanda Tangan

Pembimbing Utama

Nama : Khoirunnisa" Afandi M.Kom.

NIP : 199412282024062001

(.....)

Penguji

Penguji Utama

Nama : Fajrin Nurman Arifin, ST., M.Eng.

NIP : 198511282015041002

(.....)

Penguji Anggota

Nama : Gayatri Dwi Santika, S.SI., M.Kom.

NIP : 199201162023212044

(.....)

ABSTRAK

Inventaris nonmedis merupakan aset penting yang mendukung kelancaran pelayanan rumah sakit sehingga diperlukan pengelolaan yang efektif untuk menjaga kondisi dan ketersediaannya. Tingginya intensitas penggunaan inventaris pada ruang rawat inap kelas 3 RSD dr. Soebandi meningkatkan risiko penurunan kondisi barang, sementara distribusi data kondisi inventaris yang tidak seimbang menjadi tantangan dalam proses klasifikasi. Penelitian ini bertujuan membangun model klasifikasi kondisi inventaris nonmedis menggunakan algoritma *Random Forest* dengan penerapan *Synthetic Minority Oversampling Technique* (SMOTE), mengevaluasi performa model, serta mengembangkan *dashboard* interaktif sebagai pendukung pengambilan keputusan pemeliharaan. Penelitian menggunakan pendekatan kuantitatif deskriptif berbasis *data mining* dengan data inventaris nonmedis dari 12 ruang rawat inap kelas 3 periode triwulan tahun 2025. Tahapan penelitian meliputi *data cleaning*, *feature engineering*, *data transformation* menggunakan *One-Hot Encoding*, penyeimbangan kelas menggunakan SMOTE, pembangunan model *Random Forest*, dan evaluasi menggunakan *Stratified K-Fold Cross Validation*. Hasil penelitian menunjukkan bahwa penerapan SMOTE meningkatkan kemampuan model dalam mengenali kelas minoritas dengan meningkatkan nilai *Balanced Accuracy* dan *Recall* dari 59,82% menjadi 73,43%, serta meningkatkan tingkat klasifikasi benar pada kelas Kurang Baik dari 52,91% menjadi 72,48% dan kelas Rusak Berat dari 30,59% menjadi 64,71%. Meskipun nilai *Accuracy*, *Precision*, dan ROC-AUC sedikit menurun, analisis performa per kelas menunjukkan bahwa model menjadi lebih efektif dalam mendeteksi inventaris yang memerlukan pemeliharaan. Analisis *feature importance* menunjukkan bahwa variabel depresiasi aset merupakan variabel yang paling berpengaruh dalam proses klasifikasi. Selain itu, *dashboard* interaktif berbasis Streamlit berhasil dikembangkan sebagai *proof of concept* yang mampu melakukan *preprocessing* data secara otomatis, menampilkan hasil klasifikasi, serta menghasilkan rekomendasi prioritas pemeliharaan sehingga mendukung pengambilan keputusan yang lebih konsisten, objektif, dan berbasis data.

Kata kunci: manajemen inventaris, data mining, klasifikasi, random forest, SMOTE

RINGKASAN

Pengelolaan inventaris nonmedis merupakan salah satu aspek penting dalam mendukung kelancaran operasional rumah sakit. Pada ruang rawat inap kelas 3 RSD dr. Soebandi, tingginya intensitas penggunaan inventaris meningkatkan risiko penurunan kondisi barang, sementara distribusi data kondisi inventaris yang tidak seimbang menjadi tantangan dalam proses klasifikasi. Kondisi tersebut dapat menyebabkan keterlambatan pemeliharaan, menurunkan kualitas pelayanan, serta mengurangi efisiensi pengelolaan aset. Selain itu, penilaian kondisi inventaris yang dilakukan secara manual berpotensi menghasilkan keputusan yang berbeda karena dipengaruhi oleh subjektivitas petugas. Oleh karena itu, diperlukan pendekatan berbasis data yang mampu mengklasifikasikan kondisi inventaris secara lebih cepat, objektif, konsisten, dan terarah sebagai dasar pengambilan keputusan pemeliharaan.

Penelitian ini bertujuan membangun model klasifikasi kondisi inventaris nonmedis ruang rawat inap kelas 3 RSD dr. Soebandi menggunakan algoritma *Random Forest* dengan penerapan *Synthetic Minority Oversampling Technique* (SMOTE), mengevaluasi performa model, serta mengembangkan *dashboard* interaktif sebagai pendukung pengambilan keputusan pemeliharaan inventaris. Penelitian menggunakan pendekatan kuantitatif deskriptif berbasis *data mining*. Data diperoleh dari laporan inventaris nonmedis 12 ruang rawat inap kelas 3 periode triwulan tahun 2025 dengan total 2.322 data awal. Tahapan penelitian meliputi pengumpulan data, *data cleaning*, *feature engineering*, *data transformation* menggunakan *One-Hot Encoding*, penyeimbangan kelas menggunakan SMOTE, pembangunan model *Random Forest*, serta evaluasi menggunakan *Stratified K-Fold Cross Validation*. Variabel yang digunakan meliputi bahan, kategori, umur, harga per unit, dan depresiasi aset sebagai fitur, sedangkan kondisi inventaris digunakan sebagai variabel target. Evaluasi model dilakukan menggunakan metrik *Accuracy*, *Balanced Accuracy*, *Precision*, *Recall*, *F1-score*, dan ROC-AUC.

Hasil penelitian menunjukkan bahwa setelah proses *data cleaning* diperoleh 2.301 data inventaris dengan distribusi kelas yang tidak seimbang, yaitu 1.889 data kondisi Baik, 327 data Kurang Baik, dan 85 data Rusak Berat. Penerapan SMOTE berhasil menyeimbangkan distribusi kelas pada data pelatihan sehingga setiap kelas memiliki jumlah data yang sama. Model *Random Forest* dengan SMOTE menghasilkan *Accuracy* sebesar 80,92%, *Balanced Accuracy* 73,43%, *Precision* 61,63%, *Recall* 73,43%, *F1-score* 65,20%, dan ROC-AUC 90,65%. Dibandingkan model *Random Forest* tanpa SMOTE, penerapan SMOTE meningkatkan kemampuan model dalam mengenali kelas minoritas. Hasil *confusion matrix* menunjukkan bahwa tingkat klasifikasi benar pada kelas Kurang Baik meningkat dari 52,91% menjadi 72,48%, sedangkan pada kelas Rusak Berat meningkat dari 30,59% menjadi 64,71%. Analisis performa per kelas juga menunjukkan bahwa meskipun nilai *Precision* pada kelas minoritas menurun, peningkatan *Recall* membuktikan bahwa model lebih efektif dalam mendeteksi inventaris yang memerlukan pemeliharaan. Analisis *feature importance* menunjukkan bahwa variabel depresiasi aset merupakan faktor yang paling berpengaruh dalam menentukan kondisi inventaris, diikuti oleh umur, harga per unit, kategori, dan bahan.

Kesimpulan penelitian menunjukkan bahwa penerapan *Random Forest* dengan SMOTE mampu menghasilkan performa klasifikasi yang lebih seimbang dibandingkan *Random Forest* tanpa SMOTE, khususnya dalam mengenali kelas minoritas. *Dashboard* interaktif berbasis Streamlit berhasil dikembangkan sebagai *proof of concept* yang mampu melakukan *preprocessing* data secara otomatis, menampilkan hasil klasifikasi, visualisasi distribusi kondisi inventaris, serta menghasilkan rekomendasi prioritas pemeliharaan. Penerapan model klasifikasi dan *dashboard* tersebut mendukung proses pengambilan keputusan yang lebih konsisten, objektif, dan berbasis data sehingga berkontribusi terhadap peningkatan efisiensi pengelolaan inventaris nonmedis di lingkungan rumah sakit.

PRAKATA

Puji syukur kehadirat Allah SWT atas segala rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi berjudul “Penerapan Data Mining untuk Klasifikasi Kondisi Inventaris Nonmedis menggunakan *Random Forest* dan SMOTE sebagai Pendukung Efisiensi Manajemen di RSD Dr. Soebandi. Penelitian ini diajukan guna melengkapi tugas akhir dan memenuhi salah satu syarat untuk menyelesaikan pendidikan strata satu (S1) pada Program Studi Sistem Informasi Fakultas Ilmu Komputer Universitas Jember. Penulis menyampaikan terima kasih kepada:

1. Dekan Fakultas Ilmu Komputer Universitas Jember;
2. Kepala Program Studi Sistem Informasi Fakultas Ilmu Komputer Universitas Jember;
3. Ibu Khoirunnisa” Afandi M.Kom. selaku Dosen Pembimbing yang telah meluangkan waktu dan pikiran untuk berdiskusi hingga terselesaikannya penulisan skripsi saya;
4. Bapak Fajrin Nurman Arifin, ST., M.Eng. dan Ibu Gayatri Dwi Santika, S.SI., M.Kom. selaku Dosen Penguji yang telah memberikan kritik dan saran yang membangun dalam penyempurnaan skripsi saya;
5. Bapak Fahrobby Adnan, S.Kom., M.MSI. selaku Dosen Pembimbing Akademik yang telah memberikan arahan selama perkuliahan saya;
6. Dosen dan Karyawan Fakultas Ilmu Komputer Universitas Jember;
7. Semua pihak yang telah membantu terselesaikannya skripsi ini. Penulis juga menerima segala kritik dan saran dari seluruh pihak.

Jember, 16 Juli 2026

Penulis

DAFTAR ISI

PERSEMBAHAN.....	iii
MOTTO	iv
PERNYATAAN ORISINALITAS.....	v
HALAMAN PERSETUJUAN	vi
ABSTRAK	vii
RINGKASAN	viii
PRAKATA.....	x
DAFTAR ISI.....	xi
DAFTAR TABEL	xiv
DAFTAR GAMBAR	xv
DAFTAR LAMPIRAN	xvi
BAB 1. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Penelitian	3
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian	4
BAB 2. TINJAUAN TEORI.....	5
2.1 Kajian Literatur	5
2.2 Manajemen Inventaris Rumah Sakit	6
2.3 Inventaris Nonmedis Rumah Sakit.....	7
2.4 Depresiasi Aset.....	7
2.5 <i>Data Mining</i>	7
2.6 <i>Random Forest</i>	7
2.7 <i>Synthetic Minority Oversampling Technique (SMOTE)</i>	8
2.8 <i>Stratified K-Fold Cross Validation</i>	9
2.9 <i>Confusion Matrix</i>	9
2.10 Metrik Evaluasi	10

2.10.1 <i>Accuracy</i>	10
2.10.2 <i>Balanced Accuracy</i>	10
2.10.3 <i>Precision</i>	11
2.10.4 <i>Recall</i>	11
2.10.5 <i>F1-Score</i>	11
2.10.6 ROC-AUC.....	11
2.11 <i>Feature Importance</i>	12
2.12 <i>Dashboard Interaktif</i>	12
BAB 3. METODOLOGI PENELITIAN	13
3.1 Jenis Penelitian.....	13
3.2 Lokasi dan Waktu Penelitian.....	13
3.3 Tahapan Penelitian	13
3.3.1 Identifikasi Masalah	14
3.3.2 Studi Literatur	14
3.3.3 Pengumpulan Data	14
3.3.4 <i>Data Preprocessing</i>	15
3.3.5 Pembangunan Model.....	15
3.3.6 Evaluasi Model.....	16
3.3.7 Penyusunan <i>Dashboard</i>	16
BAB 4. HASIL DAN PEMBAHASAN	17
4.1 Gambaran Umum Data	17
4.1.1 Dataset Setiap Ruangan.....	17
4.1.2 Dataset Keseluruhan.....	18
4.1.3 Statistik Deskriptif	19
4.2 <i>Preprocessing Data</i>	19
4.2.1 <i>Data Cleaning</i>	20
4.2.2 <i>Feature Engineering</i>	21
4.2.3 <i>Data Transformation</i>	22
4.2.4 <i>Data Balancing</i>	23
4.3 Pembangunan Model.....	24
4.3.1 Model <i>Random Forest</i>	25


4.3.2 Model <i>Random Forest</i> dengan SMOTE.....	26
4.4 Evaluasi Model.....	26
4.5 Analisis Performa Model Berdasarkan Kelas	29
4.6 Analisis <i>Feature Importance</i>	31
4.7 Implementasi <i>Dashboard</i>	32
4.7.1 Halaman Beranda.....	32
4.7.2 Halaman Unggah.....	33
4.7.3 Halaman <i>Overview</i>	33
4.7.4 Halaman Prediksi	33
4.7.5 Halaman Pemeliharaan.....	33
4.8 Analisis Hasil Klasifikasi	34
BAB 5. KESIMPULAN DAN SARAN	35
5.1 Kesimpulan	35
5.2 Saran.....	36
DAFTAR PUSTAKA.....	37
LAMPIRAN.....	40

DAFTAR TABEL

Tabel 2.1 Kajian literatur peneliti.....	5
Tabel 3.1 Karakteristik data ruang rawat inap kelas 3 RSD dr. Soebandi	14
Tabel 4.1 Jumlah data ruangan rawat inap kelas 3	17
Tabel 4.2 Contoh dataset ruangan rawat inap kelas 3	18
Tabel 4.3 Distribusi kelas kondisi sebelum <i>cleaning</i>	18
Tabel 4.4 Contoh dataset yang telah digabung.....	18
Tabel 4.5 Tabel statistik deskriptif data awal	19
Tabel 4.6 Hasil handling <i>missing value</i>	20
Tabel 4.7 Jumlah data duplikat.....	21
Tabel 4.8 Hasil deteksi <i>outlier</i>	21
Tabel 4.9 Distribusi kelas kondisi setelah <i>cleaning</i>	21
Tabel 4.10 Karakteristik data setelah <i>feature engineering</i>	22
Tabel 4.11 Variabel kategorikal sebelum <i>One-Hot Encoding</i>	22
Tabel 4.12 Variabel kategorikal setelah <i>One-Hot Encoding</i>	22
Tabel 4.13 Distribusi kelas kondisi sebelum SMOTE	23
Tabel 4.14 Distribusi kelas kondisi setelah SMOTE	23
Tabel 4.15 Ringkasan tahapan preprocessing	24
Tabel 4.16 Parameter <i>Stratified K-Fold Cross Validation</i>	25
Tabel 4.17 Distribusi <i>data train-test</i> untuk setiap fold	25
Tabel 4.18 Parameter model <i>Random Forest</i>	25
Tabel 4.19 Hasil evaluasi setiap fold (<i>Random Forest</i>)	26
Tabel 4.20 Parameter algoritma SMOTE	26
Tabel 4.21 Hasil evaluasi setiap fold (<i>Random Forest</i> + SMOTE)	26
Tabel 4.22 Perbandingan hasil evaluasi model RF dengan RF + SMOTE	28
Tabel 4.23 Evaluasi model per kelas (<i>Random Forest</i>).....	30
Tabel 4.24 Evaluasi model per kelas (<i>Random Forest</i> + SMOTE).....	30
Tabel 4.25 Hasil analisis <i>feature importance</i>	31
Tabel 4.26 Perbandingan hasil klasifikasi (Melati Bawah).....	34
Tabel 4.27 Perbandingan hasil klasifikasi (Seruni).....	34

DAFTAR GAMBAR

Gambar 2.1 Skema algoritma <i>Random Forest</i>	8
Gambar 2.2 Skema algoritma SMOTE	8
Gambar 2.3 Skema <i>Stratified K-Fold Cross Validation</i>	9
Gambar 2.4 Peta <i>Confusion Matrix</i>	10
Gambar 2.5 Skema metrik ROC-AUC	12
Gambar 3.1 Skema tahapan penelitian	13
Gambar 4.1 Confusion matrix <i>Random Forest</i>	27
Gambar 4.2 Confusion matrix <i>Random Forest</i> + SMOTE	27



DAFTAR LAMPIRAN

Lampiran 1.1 Hasil wawancara prapenelitian	40
Lampiran 3.1 Data inventaris nonmedis ruang rawat inap kelas 3	40
Lampiran 4.1 Dataset inventaris nonmedis ruang rawat inap kelas 3	40
Lampiran 4.2 Kode pemahaman dataset	40
Lampiran 4.3 Kode <i>preprocessing</i> dataset.....	40
Lampiran 4.4 Kode pembangunan model <i>Random Forest</i>	40
Lampiran 4.5 Kode pembangunan model <i>Random Forest</i> + SMOTE	40
Lampiran 4.6 Kode analisis dan evaluasi model	40
Lampiran 4.7 Kode pembangunan <i>dashboard</i> interaktif	40
Lampiran 4.8 Tampilan <i>dashboard</i> interaktif	40

BAB 1. PENDAHULUAN

1.1 Latar Belakang

Menurut Undang-undang Nomor 17 Tahun 2023 tentang Kesehatan pasal 1 ayat 10, rumah sakit merupakan fasilitas pelayanan kesehatan yang menyelenggarakan pelayanan kesehatan perseorangan secara paripurna melalui pelayanan promotif, preventif, kuratif, rehabilitatif, dan/atau paliatif. Dalam penyelenggaraannya, rumah sakit didukung oleh berbagai unsur penunjang medis maupun nonmedis sebagaimana diatur dalam pasal 186 ayat 1 Undang-undang Nomor 17 Tahun 2023 tentang Kesehatan. Salah satu aspek penting dalam mendukung kelancaran operasional rumah sakit adalah pengelolaan inventaris.

Berdasarkan hasil wawancara prapenelitian dengan Kepala Instalasi Rawat Inap dan dua Kepala Ruang Rawat Inap RSD dr. Soebandi, diketahui bahwa ruang rawat inap kelas 3 merupakan unit yang memiliki jumlah inventaris nonmedis paling banyak dibandingkan kelas lainnya. Selain itu, ruang rawat inap kelas 3 memiliki *Bed Occupancy Rate* (BOR) yang mencapai $\pm 85\%$ hampir setiap harinya. Tingginya aktivitas pelayanan dan penggunaan fasilitas secara terus-menerus menyebabkan ruang rawat inap kelas 3 memiliki risiko kerusakan yang lebih tinggi dibandingkan unit lainnya.

Kerusakan inventaris nonmedis yang tidak teridentifikasi dengan baik dapat mengganggu aktivitas pelayanan dan menurunkan kualitas layanan rumah sakit. Penelitian Ratwani et al. (2023) menunjukkan bahwa 81,1% isu keselamatan yang disebabkan oleh peralatan pendukung di rumah sakit berkaitan dengan malafungsi peralatan. Selain itu, penggantian atau pemeliharaan aset yang dilakukan tanpa informasi mengenai kondisi barang dapat menyebabkan penggunaan anggaran yang kurang efektif dan berpotensi menimbulkan kerugian finansial. Penentuan kondisi inventaris yang masih dilakukan secara manual berpotensi menghasilkan penilaian yang berbeda antar petugas karena dipengaruhi oleh subjektivitas. Oleh karena itu,

diperlukan suatu pendekatan berbasis data yang mampu mengklasifikasikan kondisi inventaris secara lebih objektif, konsisten, dan dapat dijadikan dasar dalam menentukan prioritas pemeliharaan.

Penelitian ini menggunakan variabel umur, harga per unit, bahan, kategori, dan depresiasi aset untuk menentukan kondisi barang. Variabel-variabel tersebut dipilih karena berkaitan dengan karakteristik dan nilai ekonomis suatu aset yang dapat memengaruhi kondisi inventaris selama masa penggunaannya. Penggunaan depresiasi aset sebagai salah satu variabel didasarkan pada penelitian sebelumnya (Akhmadi, 2015; Anggraini et al., 2023; Boyratan & Maryoso, 2020; Denny Laksmana & Adriansyah, 2024; Harefa & Hulu, 2022).

Perkembangan *Artificial Intelligence* (AI) memungkinkan penerapan analisis prediktif dalam berbagai bidang, termasuk pengelolaan rumah sakit. AI dapat membantu meningkatkan efisiensi manajemen melalui analisis prediktif untuk pemeliharaan aset dan pengelolaan inventaris (Maleki Varnosfaderani & Forouzanfar, 2024). Pendekatan ini sejalan dengan konsep *Condition-Based Maintenance* (CBM), yaitu pemeliharaan berdasarkan kondisi aktual suatu aset sehingga tindakan pemeliharaan dapat dilakukan secara lebih efektif (Ward et al., 2024).

Metode *Random Forest* dipilih karena memiliki kemampuan klasifikasi yang baik dan telah banyak digunakan dalam berbagai penelitian (Assegie et al., 2024; Durmuş et al., 2025; Erlin et al., 2022; Jackins et al., 2021; Pal & Parija, 2021; Satrio Junaidi et al., 2024). Namun, data inventaris nonmedis yang digunakan pada penelitian ini memiliki distribusi kelas yang tidak seimbang. Ketidakseimbangan data dapat menyebabkan model cenderung mengenali kelas mayoritas dan kurang mampu mengidentifikasi kelas minoritas (Wongvorachan et al., 2023). Untuk mengatasi permasalahan tersebut digunakan metode *Synthetic Minority Oversampling Technique* (SMOTE) yang menghasilkan data sintesis pada kelas minoritas sehingga distribusi data menjadi lebih seimbang (Erlin et al., 2022).

Penelitian ini juga mengembangkan *dashboard* interaktif berbasis Streamlit sebagai *proof of concept*. *Dashboard* tidak hanya berfungsi sebagai

media visualisasi, tetapi juga sebagai alat bantu pengambilan keputusan yang lebih cepat, objektif, dan konsisten. Dengan adanya model klasifikasi dan *dashboard* interaktif, petugas dapat memfokuskan perhatian pada inventaris yang diprediksi memerlukan pemeliharaan. Pendekatan ini diharapkan mendukung penggunaan waktu, tenaga, dan sumber daya pemeliharaan secara lebih efektif.

Berdasarkan permasalahan tersebut, penelitian ini menerapkan algoritma *Random Forest* dengan SMOTE untuk mengklasifikasikan kondisi inventaris nonmedis ruang rawat inap kelas 3 RSD dr. Soebandi. Hasil klasifikasi kemudian divisualisasikan melalui *dashboard* interaktif sebagai penunjang pengambilan keputusan dalam perencanaan pemeliharaan inventaris nonmedis secara lebih efektif dan berbasis data.

1.2 Rumusan Masalah

1. Bagaimana hasil klasifikasi kondisi inventaris nonmedis ruang rawat inap kelas 3 RSD dr. Soebandi menggunakan algoritma *Random Forest* dengan SMOTE sebagai penunjang pengambilan keputusan pemeliharaan?
2. Bagaimana performa algoritma *Random Forest* dengan dan tanpa SMOTE berdasarkan metrik *Accuracy*, *Balanced Accuracy*, *Precision*, *Recall*, *F1-Score*, dan ROC-AUC?
3. Bagaimana membangun *dashboard* interaktif sebagai visualisasi hasil klasifikasi dan penunjang pengambilan keputusan pemeliharaan inventaris nonmedis?

1.3 Batasan Penelitian

1. Penelitian menggunakan data inventaris nonmedis ruang rawat inap kelas 3 RSD dr. Soebandi dari 12 ruang pada periode triwulan tahun 2025.
2. Variabel yang digunakan meliputi umur, harga per unit, bahan, kategori, dan depresiasi aset sebagai variabel input, serta kondisi barang sebagai variabel output.

3. Penanganan ketidakseimbangan data dilakukan menggunakan metode SMOTE.
4. Evaluasi model dilakukan menggunakan metrik *Accuracy*, *Balanced Accuracy*, *Precision*, *Recall*, *F1-Score*, dan ROC-AUC.
5. *Dashboard* dibangun sebagai *proof of concept* berbasis Streamlit dan dijalankan secara lokal tanpa integrasi dengan sistem informasi rumah sakit.

1.4 Tujuan Penelitian

1. Menganalisis hasil klasifikasi kondisi inventaris nonmedis ruang rawat inap kelas 3 RSD dr. Soebandi menggunakan algoritma *Random Forest* dengan SMOTE sebagai penunjang pengambilan keputusan pemeliharaan.
2. Mengevaluasi performa algoritma *Random Forest* dengan dan tanpa SMOTE berdasarkan metrik *Accuracy*, *Balanced Accuracy*, *Precision*, *Recall*, *F1-Score*, dan ROC-AUC.
3. Membangun *dashboard* interaktif berbasis Streamlit untuk memvisualisasikan hasil klasifikasi kondisi inventaris nonmedis.

1.5 Manfaat Penelitian

1. Bagi RSD dr. Soebandi, penelitian ini diharapkan dapat membantu proses klasifikasi kondisi inventaris secara lebih objektif, konsisten, dan berbasis data sehingga mendukung penentuan prioritas pemeliharaan yang lebih efisien dibandingkan penilaian manual.
2. Bagi pasien, penelitian ini diharapkan dapat mendukung kualitas pelayanan melalui ketersediaan fasilitas penunjang yang lebih terawat.
3. Bagi peneliti, penelitian ini dapat menambah pengalaman dan pemahaman dalam penerapan *Random Forest* dan SMOTE pada pengelolaan inventaris rumah sakit.
4. Bagi akademik, penelitian ini diharapkan dapat menjadi referensi pengembangan penelitian terkait klasifikasi kondisi aset dan manajemen inventaris berbasis *machine learning*.

BAB 2. TINJAUAN TEORI

2.1 Kajian Literatur

Dalam penelitian ini, peneliti mengambil beberapa artikel jurnal sebagai kajian literatur. Peneliti juga mengambil beberapa landasan teori dari artikel-artikel utama seperti yang ditampilkan pada Tabel 2.1.

Tabel 2.1 Kajian literatur peneliti

Judul	Penulis & Tahun	Metode	Hasil Penelitian	Gap Penelitian
The Role of AI in Hospitals and Clinics: Transforming Healthcare in the 21st Century	Shiva Maleki Varnosfaderani & Mohamad Forouzanfar (2024)	Review paper bersumber dari Google Scholar dan PubMed lima tahun terakhir yang mencakup AI di bidang kesehatan.	Dari berbagai paper, AI terbukti berdampak di bidang kesehatan, salah satunya pada manajemen operasional rumah sakit.	Pembahasan dalam review ini hanya membahas penggunaan AI secara umum pada bidang kesehatan.
Assessing Equipment, Supplies, and Devices for Patient Safety Issues	Ratwani, R.M., Adams, K.T., Kim, T.C., Busog, D.C., Howe, J.L., Jones, R., & Krevat, S. (2023)	Analisis deskriptif kuantitatif terkait kondisi peralatan dalam bidang kesehatan terhadap keselamatan pasien.	Hasil menunjukkan 81,1% kasus merupakan malafungsi, diikuti sterilisasi (8,9%), usabilitas (8,0%), dan kehilangan (2,0%).	Penelitian ini masih mencakup peralatan medis dan tidak menggunakan pendekatan <i>machine learning</i> .
Optimizing Healthcare Inventory Management Using Machine Learning for Efficient Classification of Medical Supplies	Alkan Durmuş, Ömer Aydin, Feriştah Dalkiliç (2025)	Analisis komparatif delapan algoritma dengan evaluasi menggunakan <i>Accuracy</i> , <i>Specificity</i> , <i>Precision</i> , <i>Recall</i> , dan <i>F1-Score</i> .	Hasil menunjukkan XGBoost memiliki akurasi tertinggi (99,59%), diikuti <i>Random Forest</i> (98,94%) dan algoritma lainnya.	Penelitian ini hanya mencakup klasifikasi peralatan medis, tidak menggunakan SMOTE dan tanpa implementasi <i>dashboard</i> interaktif.
Dampak SMOTE terhadap Kinerja Random Forest Classifier berdasarkan Data Tidak Seimbang	Erlin, Yenny Desnelita, Nurliana Nasution, Laili Suryati, Fransiskus Zoromi (2022)	Menggunakan <i>Random Forest</i> dengan dan tanpa SMOTE. Evaluasi menggunakan <i>Accuracy</i> , <i>Precision</i> , <i>Recall</i> , <i>F1-Score</i> , <i>Specificity</i> , <i>G-Mean</i> , dan <i>Youden's Index</i> , serta tuning menggunakan GridSearchCV.	Hasil menunjukkan SMOTE meningkatkan kinerja model secara konsisten, termasuk <i>Accuracy</i> (+3,45%), <i>Precision</i> (+4,8%), <i>Recall</i> (+7,1%), dan metrik lainnya, serta menghasilkan model yang lebih stabil dan tidak <i>overfitting</i> .	Penelitian ini berada pada domain kesehatan (deteksi penyakit jantung) yang merupakan klasifikasi biner, bukan multikelas dan tidak dalam konteks kondisi inventaris nonmedis.

Maleki Varnosfaderani & Forouzanfar (2024) dalam artikel “*The Role of AI in Hospitals and Clinics: Transforming Healthcare in the 21st Century*”

membahas peran AI dalam transformasi digital rumah sakit. Hasil kajian menunjukkan bahwa AI dapat meningkatkan efisiensi manajemen operasional rumah sakit. Penelitian tersebut menjadi dasar penerapan AI untuk membantu klasifikasi kondisi inventaris nonmedis.

Ratwani et al. (2023) dalam penelitian "*Assessing Equipment, Supplies, and Devices for Patient Safety Issues*" menganalisis permasalahan keselamatan pasien yang berkaitan dengan peralatan rumah sakit. Hasil penelitian menunjukkan bahwa 81,1% masalah disebabkan oleh malafungsi peralatan. Temuan ini menjadi dasar pentingnya klasifikasi kondisi inventaris nonmedis untuk mengurangi risiko malafungsi.

Durmuş et al. (2025) dalam penelitian "*Optimizing Healthcare Inventory Management Using Machine Learning for Efficient Classification of Medical Supplies*" membandingkan delapan algoritma *machine learning* untuk klasifikasi inventaris medis. Hasil penelitian menunjukkan bahwa XGBoost (99,59%) dan *Random Forest* (98,94%) memiliki performa terbaik. Penelitian tersebut menjadi dasar pemilihan *Random Forest* sebagai metode klasifikasi.

Erlin et al. (2022) dalam penelitian "*Dampak SMOTE terhadap Kinerja Random Forest Classifier berdasarkan Data Tidak Seimbang*" mengevaluasi pengaruh SMOTE terhadap *Random Forest* pada klasifikasi penyakit jantung. Hasil penelitian menunjukkan bahwa SMOTE meningkatkan *Accuracy*, *Precision*, dan *Recall* model. Temuan tersebut menjadi dasar penggunaan SMOTE sebagai metode penanganan ketidakseimbangan data.

2.2 Manajemen Inventaris Rumah Sakit

Manajemen inventaris merupakan proses pengadaan, penyimpanan, pengelolaan, dan pengawasan terhadap aset agar dapat mendukung kelancaran operasional organisasi (Nuril Izza & Muzid, 2025). Pengelolaan inventaris yang baik dapat mengurangi risiko kekurangan maupun kelebihan persediaan serta meningkatkan efisiensi penggunaan anggaran.

2.3 Inventaris Nonmedis Rumah Sakit

Inventaris nonmedis di rumah sakit adalah perlengkapan penunjang dalam menyempurnakan dan melengkapi pelayanan medis di rumah sakit yaitu berkaitan dengan pelayanan administrasi dan kegiatan operasional baik untuk kepentingan pasien dan pegawai rumah sakit dalam menjalankan aktivitasnya (Mulyana et al., 2023).

2.4 Depresiasi Aset

Depresiasi atau penyusutan aset merupakan penurunan nilai suatu aset selama masa penggunaannya. Nilai penyusutan dapat digunakan untuk mengetahui penurunan nilai ekonomis suatu barang seiring bertambahnya usia penggunaan (Akhmadi, 2015). Ada dua metode depresiasi aset, Metode Garis Lurus (2.1) dan Saldo Menurun Ganda (2.2).

$$\text{Depresiasi Aset} = \frac{\text{Harga Perolehan Aset} - \text{Nilai Residu}}{\text{Masa Manfaat (Tahun)}} \quad (2.1)$$

$$\text{Depresiasi Aset} = \text{Nilai Awal} \times \left(2 \times \frac{100\%}{\text{Masa Manfaat (Tahun)}} \right) \quad (2.2)$$


2.5 Data Mining

Data Mining adalah proses pengumpulan dan pengolahan data yang bertujuan untuk mengekstrak informasi penting pada data. *Data Mining* bisa berfungsi sebagai sarana penjelasan, konfirmasi, dan eksplorasi (Setiawan, 2021). Salah satu jenis *data mining* adalah klasifikasi, Klasifikasi merupakan metode *supervised learning* yang bertujuan memprediksi kategori atau kelas suatu objek berdasarkan data historis yang telah diketahui labelnya (Setiawan, 2021).

2.6 Random Forest

Random Forest adalah algoritma *supervised learning* yang bisa digunakan untuk klasifikasi maupun regresi, algoritma ini paling fleksibel dan mudah digunakan. *Random Forest* terdiri dari beberapa pohon keputusan. Semakin banyak pohon keputusan yang dimiliki, semakin kuat algoritma *Random Forest* tersebut (Erlin et al., 2022). Skema *Random Forest* bisa dilihat pada

Gambar 2.1. Formula *Random Forest* dibagi menjadi Klasifikasi (2.3) dan Regresi (2.4).



Gambar 2.1 Skema algoritma *Random Forest*

$$y' = \text{Majority Vote}\{f_1(x), f_2(x), \dots, f_m(x)\} \quad (2.3)$$

$$y' = \frac{1}{m} \sum_{j=1}^m f_j(x) \quad (2.4)$$


y' = prediksi akhir

m = jumlah pohon keputusan dalam hutan

$f_j(x)$ = Prediksi dari pohon ke j pada input x

2.7 Synthetic Minority Oversampling Technique (SMOTE)

SMOTE adalah metode *oversampling* yang paling umum digunakan untuk menyelesaikan masalah ketidakseimbangan distribusi data. SMOTE bertujuan untuk menyeimbangkan distribusi kelas dengan meningkatkan jumlah kelas minoritas dan meningkatkan kemampuan model dalam mengenali kelas minoritas. (Erlin et al., 2022). Skema algoritma SMOTE bisa dilihat pada Gambar 2.2. Formula SMOTE bisa dilihat pada (2.5).



Gambar 2.2 Skema algoritma SMOTE

$$x_{new} = x_i + rand(0,1) \times (x_{si} + x_i) \quad (2.5)$$


x_i = sampel data asli (minoritas)

x_{si} = KNN yang dipilih acak dari x_i dalam kelas yang sama

$rand(0,1)$ = angka acak antara 0 dan 1

2.8 Stratified K-Fold Cross Validation

Stratified K-Fold Cross Validation merupakan metode evaluasi yang membagi dataset menjadi beberapa *fold*. Metode ini dirancang untuk memastikan bahwa setiap *fold* memiliki distribusi target yang sama seperti dataset asli (Rina, 2023a). Skema *Stratified K-Fold Cross Validation* bisa dilihat pada Gambar 2.3.



Gambar 2.3 Skema *Stratified K-Fold Cross Validation*

2.9 Confusion Matrix

Confusion Matrix adalah alat yang digunakan untuk menggambarkan kinerja model klasifikasi pada data uji yang sudah diketahui hasil sebenarnya (Rina, 2023b). *Confusion Matrix* terdiri atas *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Peta *Confusion Matrix* bisa dilihat pada Gambar 2.4.

		Actual	
		True	False
Prediction	True	True Positive (TP)	False Positive (FP)
	False	False Negative (FN)	True Negative (TN)

Gambar 2.4 Peta *Confusion Matrix*

2.10 Metrik Evaluasi

Metrik evaluasi digunakan untuk mengukur kemampuan model klasifikasi dalam menghasilkan prediksi yang sesuai dengan data sebenarnya. Penelitian ini menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-Score*, *Balanced Accuracy*, dan ROC-AUC.

2.10.1 Accuracy

Accuracy memberikan gambaran mengenai seberapa sering model memprediksi kelas yang benar, baik itu kelas positif maupun negatif (Rina, 2023b). *Accuracy* tidak selalu menjadi indikator terbaik pada kasus data tidak seimbang karena model dapat memperoleh nilai *Accuracy* yang tinggi hanya dengan memprediksi kelas mayoritas secara dominan. Formula metrik *Accuracy* adalah sebagai berikut (2.6).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.6)$$

2.10.2 Balanced Accuracy

Balanced Accuracy merupakan metrik evaluasi yang menghitung rata-rata nilai *recall* dari setiap kelas. *Balanced Accuracy* dianggap lebih representatif dalam mengevaluasi model klasifikasi pada penelitian yang memiliki distribusi kelas yang tidak seimbang (Zach, 2021). Formula metrik *Balanced Accuracy* adalah sebagai berikut (2.7)

$$Balanced Accuracy = \frac{Recall_1 + Recall_2 + Recall_n}{n} \quad (2.7)$$

n = Jumlah Kelas dalam Klasifikasi

2.10.3 Precision

Precision memberikan gambaran mengenai seberapa sering model memprediksi kelas positif dengan benar, di antara semua prediksi positif yang dibuat oleh model (Rina, 2023b). Semakin tinggi nilai *Precision*, semakin kecil kemungkinan model memberikan prediksi positif yang salah. Formula metrik *Precision* adalah sebagai berikut (2.8).

$$Precision = \frac{TP}{TP+FP} \quad (2.8)$$

2.10.4 Recall

Recall merupakan metrik yang digunakan untuk mengukur kemampuan model dalam mengidentifikasi kelas positif dengan benar (Rina, 2023b). Nilai *Recall* yang tinggi menunjukkan bahwa model mampu mengidentifikasi sebagian besar data dari kelas tertentu dengan baik dan meminimalkan terjadinya kesalahan negatif. Formula metrik *Recall* adalah sebagai berikut (2.9).

$$Recall = \frac{TP}{TP+FN} \quad (2.9)$$

2.10.5 F1-Score


F1-Score merupakan metrik yang digunakan untuk memperoleh keseimbangan antara kemampuan model dalam menghasilkan prediksi yang akurat (Rina, 2023b). *F1-Score* sangat berguna pada kasus klasifikasi dengan distribusi data yang tidak seimbang karena dapat memberikan gambaran performa model secara lebih menyeluruh. Formula metrik *F1-Score* adalah sebagai berikut (2.10)

$$F1\ Score = 2 \times \frac{Recall \times Precision}{Recall + Precision} \quad (2.10)$$

2.10.6 ROC-AUC

ROC-AUC (*Receiver Operating Characteristic – Area Under Curve*) merupakan metrik evaluasi yang digunakan untuk mengukur kemampuan model dalam membedakan antar kelas berdasarkan probabilitas prediksi yang dihasilkan dengan memperhatikan *trade-off*

antara tingkat *True Positive Rate* (TPR) dan tingkat *False Positive Rate* (FPR) (Andi, 2023). Skema metrik ROC-AUC dapat dilihat pada Gambar 2.5.



Gambar 2.5 Skema metrik ROC-AUC

2.11 Feature Importance

Feature Importance merupakan teknik yang digunakan untuk mengetahui tingkat pengaruh masing-masing variabel terhadap hasil prediksi model. *Feature Importance* merupakan konsep penting dalam *machine learning* yang membantu meningkatkan keterbacaan, kinerja, dan efisiensi model (Lomash Bhuva, 2025).

2.12 Dashboard Interaktif

Dashboard interaktif merupakan media visualisasi yang digunakan untuk menyajikan informasi dalam bentuk tabel, grafik, dan diagram sehingga memudahkan pengguna dalam memahami hasil analisis. Pada penelitian ini dashboard dibangun menggunakan *framework* Streamlit sebagai *proof of concept* untuk menampilkan hasil klasifikasi, distribusi data, 9 dan prioritas pemeliharaan inventaris nonmedis.

BAB 3. METODOLOGI PENELITIAN

3.1 Jenis Penelitian


Penelitian ini merupakan penelitian kuantitatif deskriptif dengan pendekatan *data mining*. Menurut Sugiyono (2019), metode penelitian yang berlandaskan filsafat positivisme dan digunakan untuk menguji hipotesis melalui pengolahan data secara objektif. Penelitian ini merupakan penelitian kuantitatif deskriptif dengan pendekatan berbasis *data mining*.

3.2 Lokasi dan Waktu Penelitian

Penelitian dilaksanakan di Instalasi Rawat Inap RSD dr. Soebandi Kabupaten Jember. Objek penelitian difokuskan pada ruang rawat inap kelas 3 yang terdiri dari 12 ruangan.

3.3 Tahapan Penelitian

Penelitian dilakukan secara bertahap mulai dari identifikasi masalah hingga implementasi *dashboard* interaktif. Tahapan penelitian dilakukan untuk memperoleh model klasifikasi yang dapat digunakan sebagai penunjang pengambilan keputusan pemeliharaan inventaris nonmedis. Skema tahapan penelitian bisa dilihat pada Gambar 3.1.



Gambar 3.1 Skema tahapan penelitian

3.3.1 Identifikasi Masalah

Tahap identifikasi masalah dilakukan melalui wawancara prapenelitian dengan Kepala Instalasi Rawat Inap dan dua kepala ruang sebagai perwakilan dari ruang rawat inap kelas 3. Berdasarkan hasil wawancara diperoleh informasi bahwa ruang rawat inap kelas 3 memiliki jumlah inventaris nonmedis yang paling banyak dan memiliki tingkat *Bed Occupancy Rate* (BOR) yang tinggi. Tingginya intensitas ini menyebabkan risiko kerusakan inventaris nonmedis menjadi lebih besar.

3.3.2 Studi Literatur

Tahap studi literatur dilakukan dengan mengumpulkan berbagai referensi yang relevan dari jurnal, buku, dan artikel ilmiah. Studi literatur dilakukan untuk memperoleh landasan teori mengenai manajemen inventaris rumah sakit, depresiasi aset, *data mining*, *Random Forest*, *SMOTE*, *Stratified K-Fold Cross Validation*, metrik evaluasi, dan *dashboard* interaktif. Hasil studi literatur juga digunakan sebagai dasar dalam menentukan metode yang digunakan dalam penelitian.

3.3.3 Pengumpulan Data

Data penelitian diperoleh dari laporan inventaris nonmedis ruang rawat inap kelas 3 RSD dr. Soebandi periode triwulan tahun 2025. Data berasal dari 12 ruangan dan telah disahkan oleh kepala ruangan masing-masing. Karakteristik data awal bisa dilihat pada Tabel 3.1.

Tabel 3.1 Karakteristik data ruang rawat inap kelas 3 RSD dr. Soebandi

Variabel	Tipe Data	Keterangan
nama barang	string	Nama barang di dalam inventaris
bahan	string	Bahan dasar barang
kategori	string	Kategori barang
tahun pembelian	integer	Tahun pengadaan barang
jumlah	integer	Jumlah/stok barang
harga	integer	Harga barang sesuai jumlah
kondisi	string	Kelas kondisi (baik, kurang baik, rusak berat)

3.3.4 Data Preprocessing

Tahap *preprocessing* dilakukan untuk menghasilkan dataset yang siap digunakan dalam proses klasifikasi. Tahap ini meliputi beberapa proses, yaitu:

1. Data Cleaning

Tahap ini dilakukan untuk mengatasi *missing value*, menghilangkan duplikasi yang tidak valid, serta memperbaiki inkonsistensi penulisan data agar diperoleh dataset yang lebih bersih dan konsisten. *Data cleaning* dilakukan secara manual melalui aplikasi *spreadsheet* dan otomatis menggunakan kode python.

2. Feature Engineering

Pada tahap ini dilakukan pembentukan variabel baru berupa umur barang, harga per unit, dan depresiasi aset. Variabel tersebut digunakan sebagai fitur yang merepresentasikan karakteristik dan nilai ekonomis aset.

3. Data Transformation

Variabel kategorikal berupa bahan dan kategori ditransformasikan menjadi bentuk numerik menggunakan *One-Hot Encoding* agar dapat diproses oleh algoritma *machine learning*.

4. Data Balancing

Karena distribusi kelas kondisi barang tidak seimbang, dilakukan *oversampling* menggunakan metode SMOTE pada data pelatihan sehingga model mampu mengenali kelas minoritas dengan lebih baik.

3.3.5 Pembangunan Model

Tahap ini dilakukan dengan membangun dua model klasifikasi, yaitu *Random Forest* tanpa SMOTE dan *Random Forest* dengan SMOTE. Variabel input yang digunakan meliputi bahan, kategori, umur, harga per

unit, dan depresiasi aset, sedangkan variabel output berupa kondisi barang. Proses pelatihan dan pengujian model dilakukan menggunakan metode *Stratified K-Fold Cross Validation* untuk menjaga proporsi distribusi kelas pada setiap *fold*.

3.3.6 Evaluasi Model

Evaluasi model dilakukan untuk membandingkan performa *Random Forest* tanpa SMOTE dan *Random Forest* dengan SMOTE. Evaluasi dilakukan menggunakan *confusion matrix* dan metrik evaluasi *Accuracy*, *Precision*, *Recall*, *Balanced Accuracy*, *F1-Score*, dan ROC-AUC. Selain itu, dilakukan analisis tambahan seperti *feature importance*.

3.3.7 Penyusunan Dashboard

Tahap implementasi dilakukan dengan membangun *dashboard* interaktif berbasis Python menggunakan *framework* Streamlit. Dashboard dikembangkan sebagai *proof of concept* untuk memvisualisasikan hasil klasifikasi kondisi inventaris nonmedis. *Dashboard* terdiri dari beberapa halaman yang menampilkan ringkasan data, distribusi kelas, hasil prediksi, serta prioritas pemeliharaan. *Dashboard* dijalankan secara lokal dan tidak diintegrasikan dengan sistem informasi rumah sakit.

BAB 4. HASIL DAN PEMBAHASAN

4.1 Gambaran Umum Data

Data yang digunakan dalam penelitian ini merupakan data inventaris nonmedis ruang rawat inap kelas 3 RSD dr. Soebandi yang berjumlah 12 ruangan, diperoleh melalui laporan inventaris triwulan tahun 2025. Proses pengolahan data diawali dengan pengumpulan dan penggabungan data menjadi satu dataset penelitian. Variabel yang memiliki *missing value* diisi secara manual menggunakan aplikasi *spreadsheet*, kecuali variabel harga yang nanti akan diselesaikan di tahapan *preprocessing*.

Proses penggabungan dilakukan agar seluruh data inventaris dapat dianalisis secara menyeluruh menggunakan model klasifikasi. Dataset hasil penggabungan selanjutnya menjadi dataset mentah yang digunakan pada tahap *preprocessing* sebelum dilakukan proses klasifikasi menggunakan algoritma *Random Forest* dan SMOTE.

4.1.1 Dataset Setiap Ruangan

Setiap ruangan memiliki data inventaris yang berbeda baik dari jumlah barang maupun jenis inventaris yang digunakan. Seluruh data masih tersimpan secara terpisah sehingga belum dapat langsung digunakan sebagai dataset penelitian. Jumlah data dari masing-masing ruangan dapat dilihat pada Tabel 4.1 dan tabel contoh dataset ruangan bisa dilihat pada Tabel 4.2.

Tabel 4.1 Jumlah data ruangan rawat inap kelas 3

Nama Ruangan	Jumlah Data
Adenium	190
Anturium	197
Aster	118
Dahlia	192
Gardena	278
Lavender	101
Mawar	172
Melati A	165
Melati B	171
Sakura	371
Seruni	183
Tulip	184
Total	2322

Tabel 4.2 Contoh dataset ruangan rawat inap kelas 3

nama_barang	bahan	kategori	tahun_pembelian	jumlah	harga	kondisi
Lemari Sepatu Dua Pintu	Kayu	Furnitur	2014	1	2400000	Baik
Printer Canon	Besi	Elektronik	2014	1	1350000	Baik
Kursi Roda	Besi	Pelengkap	2014	1	1149500	Baik
...	...	...	...	...	...	...
AC Daikin 2 PK	Besi	Elektronik	2023	3	31742500	Baik

Setelah seluruh data dikumpulkan, setiap *file* masih memiliki struktur atribut yang sama, yaitu nama barang, bahan, kategori, tahun pembelian, jumlah, harga, serta kondisi. Kondisi ini memudahkan proses penggabungan menjadi satu dataset penelitian nanti.

4.1.2 Dataset Keseluruhan

Penggabungan dilakukan dengan mempertahankan seluruh atribut pada masing-masing data tanpa mengubah isi data. Dataset mentah ditambahkan atribut triwulan dan nama ruangan sebagai identifikasi tambahan untuk dataset gabungan. Dataset hasil penggabungan inilah yang digunakan sebagai input pada tahap *preprocessing*.

Dataset mentah hasil penggabungan terdiri atas 2.322 data inventaris dengan atribut triwulan, nama ruangan, nama barang, bahan, kategori, tahun pembelian, jumlah, harga, dan kondisi. Distribusi kelas kondisi sebelum *data cleaning* bisa dilihat pada Tabel 4.3 dan contoh dataset yang telah digabung bisa dilihat pada Tabel 4.4.

Tabel 4.3 Distribusi kelas kondisi sebelum *cleaning*

Kondisi	Jumlah
Baik	1909
Kurang Baik	327
Rusak Berat	86
Total	2322

Tabel 4.4 Contoh dataset yang telah digabung

triwulan	nama_ruangan	nama_barang	bahan	kategori	tahun_pembelian	jumlah	harga	kondisi
Q1	Adenium	Lemari Sepatu Dua Pintu	Kayu	Furnitur	2014	1	2400000	Baik
Q1	Adenium	Printer	Besi	Elektronik	2014	1	1350000	Baik

triwulan	nama_ ruangan	nama_ barang	bahan	kategori	tahun_ pembelian	jumlah	harga	kondisi
Q1	Adenium	Kursi Roda	Besi	Pelengkap	2014	1	1149500	Baik
...	...	...	...	...	...	...	...	...
Q4	Tulip	AC Split 2 PK	Besi	Elektronik	2023	3	3174250 0	Baik

4.1.3 Statistik Deskriptif

Analisis ini bertujuan untuk mengetahui karakteristik dasar data, seperti nilai rata-rata, simpangan baku, nilai minimum, dan nilai maksimum. Informasi tersebut memberikan gambaran awal mengenai kondisi data sekaligus menjadi acuan dalam menentukan tahapan *preprocessing* yang diperlukan.

Statistik deskriptif dilakukan terhadap variabel tahun pembelian, jumlah, dan harga. Hasil statistik deskriptif menunjukkan bahwa ketiga variabel memiliki rentang nilai yang cukup bervariasi, terutama pada variabel harga yang memiliki selisih cukup besar antara nilai minimum dan maksimum. Variasi tersebut menunjukkan bahwa inventaris nonmedis terdiri atas berbagai jenis barang dengan karakteristik dan nilai ekonomi yang berbeda. Statistik deskriptif untuk setiap variabel numerik dapat dilihat pada Tabel 4.5.

Tabel 4.5 Tabel statistik deskriptif data awal

Statistik	tahun pembelian	jumlah	harga
count	2322	2322	1029
mean	2018.910	3.656331	12257310
std	3.617362	13.47284	40358500
min	2011	1	10000
25%	2016	1	1350000
50%	2019	1	3220000
75%	2022	3	6615000
max	2025	240	398284500

4.2 Preprocessing Data

Preprocessing dilakukan untuk meningkatkan kualitas data sebelum digunakan pada proses klasifikasi menggunakan algoritma *Random Forest*. Dataset gabungan dari seluruh ruang rawat inap kelas 3 masih berupa dataset mentah yang mengandung beberapa karakteristik yang perlu diproses lebih

lanjut, seperti adanya *missing value*, inkonsistensi penulisan, serta atribut yang belum sesuai dengan kebutuhan model. Selain itu, dilakukan pembentukan atribut baru melalui *feature engineering* dan penyeimbangan distribusi kelas menggunakan SMOTE pada model RF + SMOTE, agar model dapat menghasilkan performa klasifikasi yang lebih optimal.

4.2.1 Data Cleaning

Proses ini meliputi pemeriksaan *missing value*, penghapusan data duplikat, standarisasi format penulisan, serta deteksi *outlier*. Seluruh proses dilakukan agar data yang digunakan memiliki kualitas yang baik dan sesuai dengan kebutuhan algoritma *Random Forest*.

Banyak sekali ditemukan *missing value* dan kesalahan penulisan di dalam dataset, namun seluruh variabel (selain kolom harga) dapat dibersihkan secara manual menggunakan aplikasi *spreadsheet*. Jumlah *missing value* dalam kolom harga sebanyak 1293 data diisi dengan harga barang dengan nama yang sama, jika tidak ada barang dengan nama yang sama maka akan diisi dengan rata-rata dari bahan dan kategori yang sama. Perbandingan sebelum dan setelah *handling missing value* dapat dilihat pada Tabel 4.6.

Tabel 4.6 Hasil *handling missing value*

Nama Barang	Bahan	Kategori	Harga Sebelum	Harga Sesudah
Exhaust Fan	Besi	Elektronik	N/A	850000
TV LG 32"	Besi	Elektronik	N/A	3900000
Bracket Bervin	Besi	Pelengkap	N/A	187500
...	...	...	...	...
2 Crank Gatch Bed Paramount	Besi	Pelengkap	N/A	9904374

Jumlah data duplikat yang ditemukan sebanyak 160 data. Data duplikat yang merupakan representasi dari barang yang sama namun berada pada ruangan dan periode berbeda sebanyak 139 data tetap dipertahankan, sedangkan duplikasi yang tidak valid sebanyak 21 data dihapus dari dataset. Jumlah data duplikat dapat dilihat pada Tabel 4.7.

Tabel 4.7 Jumlah data duplikat

Jenis Duplikat	Jumlah
Valid	139
Tidak Valid	21
Keseluruhan	160

Deteksi *outlier* dilakukan menggunakan metode *Interquartile Range* (IQR) terhadap atribut numerik. Berdasarkan hasil deteksi, ditemukan beberapa data yang berada di luar batas IQR terutama pada atribut harga. Meskipun begitu, data tersebut tidak dihapus karena masih merepresentasikan kondisi inventaris yang sebenarnya dan bukan merupakan kesalahan pencatatan. Nilai yang tidak wajar berasal dari jenis barang tertentu yang memang memiliki harga yang jauh lebih besar dibandingkan inventaris lainnya sehingga masih layak dipertahankan. Hasil deteksi *outlier* dapat dilihat pada Tabel 4.8. dan distribusi kelas kondisi inventaris setelah *data cleaning* dapat dilihat pada Tabel 4.9.

Tabel 4.8 Hasil deteksi *outlier*

Variabel	Jumlah Outlier	Persentase
tahun pembelian	0	0%
jumlah	261	11.34%
harga	145	6.30%

Tabel 4.9 Distribusi kelas kondisi setelah *cleaning*

Kondisi	Jumlah
Baik	1889
Kurang Baik	327
Rusak Berat	85
Total	2301

4.2.2 Feature Engineering

Feature engineering dilakukan untuk membentuk variabel yang lebih relevan terhadap kondisi inventaris. Variabel yang digunakan dalam penelitian ini adalah nama barang, bahan, kategori, umur, harga per unit, dan depresiasi aset. Karakteristik data setelah *feature engineering* bisa dilihat pada Tabel 4.9.

Tabel 4.10 Karakteristik data setelah *feature engineering*

Variabel	Tipe Data	Keterangan
nama_barang	string	Nama barang di dalam inventaris
bahan	string	Bahan dasar barang
kategori	string	Kategori barang
umur	integer	Selisih tahun penelitian dengan tahun pembelian
harga_per_unit	integer	Pembagian total harga terhadap jumlah barang
depresiasi_aset	integer	Nilai penyusutan aset sesuai kategori barang
kondisi	string	Kelas kondisi (baik, kurang baik, rusak berat)

4.2.3 Data Transformation

Tahap *data transformation* dilakukan untuk mengubah variabel kategorik (bahan dan kategori.) menjadi bentuk numerik sehingga dapat diproses oleh algoritma *Random Forest*. Algoritma *machine learning* tidak dapat melakukan proses pembelajaran secara langsung terhadap data bertipe *string* sehingga diperlukan proses *encoding* sebelum model dibangun.

Penelitian ini menggunakan metode *One-Hot Encoding* terhadap variabel bahan dan kategori. Metode tersebut membentuk variabel biner baru untuk setiap kategori unik sehingga tidak memberikan hubungan ordinal antar kategori. Pemilihan *One-Hot Encoding* dilakukan karena kedua variabel tersebut bersifat nominal dan tidak memiliki urutan tertentu. Perbandingan variabel kategorikal sebelum dan sesudah *One-Hot Encoding* bisa dilihat pada Tabel 4.11 dan Tabel 4.12.

Tabel 4.11 Variabel kategorikal sebelum *One-Hot Encoding*

Bahan	Kategori
Kayu	Furnitur
Besi	Elektronik
Besi	Pelengkap

Tabel 4.12 Variabel kategorikal setelah *One-Hot Encoding*

bahan_Besi	bahan_Kaca	bahan_Kain	bahan_Kayu	kategori_Elektronik	kategori_Furnitur	kategori_Pelengkap
0	0	0	1	0	1	0
1	0	0	0	1	0	0
1	0	0	0	0	0	1

Setelah proses *encoding* selesai dilakukan, seluruh variabel kategorikal berhasil diubah menjadi atribut numerik berbentuk biner

dengan nilai 0 dan 1 untuk nantinya digabung dengan variabel numerik hasil *feature engineering* sehingga memenuhi kebutuhan input algoritma *Random Forest*.

4.2.4 Data Balancing

Proses *data balancing* dilakukan menggunakan algoritma SMOTE khusus pembangunan model *Random Forest* + SMOTE. SMOTE akan menyeimbangkan distribusi kelas kondisi pada data inventaris. Distribusi kelas kondisi inventaris sebelum *preprocessing* dapat dilihat pada Tabel 4.13.

Tabel 4.13 Distribusi kelas kondisi sebelum SMOTE

Kondisi	Jumlah	Persentase
Baik	1889	82.09%
Kurang Baik	327	14.21%
Rusak Berat	85	3.69%

Berdasarkan distribusi tersebut terlihat bahwa dataset memiliki ketidakseimbangan kelas, di mana kelas Baik memiliki jumlah data yang lebih banyak dibandingkan kelas lainnya. Kondisi ini berpotensi membuat model cenderung mempelajari kelas mayoritas sehingga diperlukan penanganan ketidakseimbangan data menggunakan SMOTE. Distribusi kelas kondisi setelah dilakukan *data balancing* bisa dilihat pada Tabel 4.14.

Tabel 4.14 Distribusi kelas kondisi setelah SMOTE

Kondisi	Jumlah	Persentase
Baik	1889	33.3%
Kurang Baik	1889	33.3%
Rusak Berat	1889	33.3%

Setelah seluruh tahapan *preprocessing* selesai dilakukan, dataset sudah dapat diproses menggunakan algoritma *Random Forest*. Proses *data cleaning* berhasil menghasilkan dataset yang lebih konsisten, sedangkan *feature engineering* dan *data transformation* menghasilkan atribut yang lebih representatif dalam menggambarkan karakteristik inventaris nonmedis. Selain itu, penerapan SMOTE pada tahap *data balancing* menghasilkan distribusi kelas yang lebih seimbang sehingga diharapkan mampu meningkatkan kemampuan model dalam

mengenali setiap kelas kondisi inventaris. Ringkasan hasil dari setiap tahapan *preprocessing* dapat dilihat pada Tabel 4.15.

Tabel 4.15 Ringkasan tahapan preprocessing

Masalah	Kondisi Awal	Hasil
<i>Missing Value</i>	Data kosong pada variabel harga sebanyak 1293 data	Data kosong berjumlah 0
Data Duplikat	Duplikat tidak valid sebanyak 21 dan valid sebanyak 129	21 data duplikat dihapus
<i>Outlier</i>	Variabel jumlah dan harga memiliki outlier	<i>Outlier</i> tidak dihapus karena memiliki merepresentasikan kondisi inventaris sebenarnya
<i>Feature Engineering</i>	Belum ada atribut turunan	Atribut turunan seperti umur, harga per unit dan depresiasi aset
<i>Labeling Data</i>	Data kategorik belum diberi label	Data kategorik sudah dilabeli
<i>Imbalanced Data</i>	Distribusi kelas kondisi tidak seimbang	Distribusi kelas kondisi menjadi seimbang

4.3 Pembangunan Model

Sebelum dilakukan proses pelatihan model, dataset dibagi menggunakan metode *Stratified K-Fold Cross Validation* untuk memperoleh evaluasi model yang lebih stabil dan representatif. Berbeda dengan *train-test split*, metode ini membagi dataset menjadi beberapa subset (*fold*) dengan tetap mempertahankan proporsi masing-masing kelas pada setiap *fold*. Pada penelitian ini digunakan *5-fold cross validation*, sehingga pada setiap iterasi sekitar 80% data digunakan sebagai data pelatihan dan 20% sisanya digunakan sebagai data pengujian. Proses tersebut dilakukan sebanyak lima kali hingga setiap *fold* memperoleh kesempatan menjadi data pengujian satu kali.

Proporsi data tersebut dipilih karena merupakan konfigurasi yang umum digunakan dalam penelitian *machine learning* serta mampu memberikan keseimbangan antara jumlah data yang digunakan untuk mempelajari pola dan untuk mengevaluasi performa model. Penggunaan data pelatihan yang lebih besar memungkinkan algoritma mempelajari karakteristik setiap kelas, sedangkan data pengujian sebesar 20% dinilai cukup representatif untuk mengevaluasi kemampuan model terhadap data yang belum pernah dipelajari sebelumnya. Parameter *Stratified K-Fold Cross Validation* bisa dilihat pada Tabel 4.16 dan distribusi data *train-test* untuk setiap *fold* bisa dilihat pada Tabel 4.17.

Tabel 4.16 Parameter *Stratified K-Fold Cross Validation*

Parameter	Nilai
n_splits	5
shuffle	True
random_state	42

Tabel 4.17 Distribusi data *train-test* untuk setiap *fold*

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Training	1840	1841	1841	1841	1841
Testing	461	460	460	460	460

Dengan kombinasi pembagian data 80:20 pada setiap iterasi, model memperoleh data pelatihan yang cukup untuk membangun pola klasifikasi sekaligus data pengujian yang memadai untuk mengevaluasi kemampuan generalisasi model secara lebih konsisten.

Pada setiap iterasi, model dilatih menggunakan data pelatihan kemudian dievaluasi menggunakan data pengujian. Nilai *Accuracy*, *Balanced Accuracy*, *Precision*, *Recall*, *F1-Score*, dan ROC-AUC dari setiap *fold* selanjutnya dirata-ratakan sehingga diperoleh estimasi performa model yang lebih stabil dibandingkan evaluasi menggunakan satu kali pembagian data.

4.3.1 Model *Random Forest*

Pembangunan model *Random Forest* tidak melibatkan algoritma SMOTE sebagai penanganan ketidakseimbangan data. Nilai parameter yang digunakan merupakan nilai *default* dari *library* sklearn, pemilihan nilai ini dianggap cukup untuk menangani masalah klasifikasi secara umum. Parameter algoritma *Random Forest* yang digunakan bisa dilihat pada Tabel 4.18 dan hasil evaluasi setiap *fold* model *Random Forest* bisa dilihat pada Tabel 4.19.

Tabel 4.18 Parameter model *Random Forest*

Parameter	Nilai
n_estimators	100
random_state	42

Tabel 4.19 Hasil evaluasi setiap *fold* (*Random Forest*)

Fold	Accuracy	Balanced Accuracy	Precision	Recall	F1-Score	ROC-AUC
1	0.874187	0.626145	0.747398	0.626145	0.669424	0.938654
2	0.873913	0.544819	0.748967	0.544819	0.580372	0.877398
3	0.882609	0.585798	0.760246	0.585798	0.635259	0.927282
4	0.865217	0.609443	0.701046	0.609443	0.645921	0.925253
5	0.876087	0.624876	0.717662	0.624876	0.661192	0.933769
Rata-rata	0.874403	0.598216	0.735064	0.598216	0.638434	0.919312

4.3.2 Model *Random Forest* dengan SMOTE

Pembangunan model dilakukan menggunakan parameter *Random Forest* dan metode validasi model yang sama seperti sebelumnya, kemudian ditambahkan algoritma SMOTE. SMOTE berfungsi untuk mengatasi ketidakseimbangan kelas dengan melakukan *oversampling* data minoritas. Parameter SMOTE bisa dilihat pada Tabel 4.20 dan hasil evaluasi setiap *fold* model *Random Forest* dengan SMOTE bisa dilihat pada Tabel 4.21.

Tabel 4.20 Parameter algoritma SMOTE

Parameter	Nilai
random state	42

Tabel 4.21 Hasil evaluasi setiap *fold* (*Random Forest* + SMOTE)


Fold	Accuracy	Balanced Accuracy	Precision	Recall	F1-Score	ROC-AUC
1	0.778742	0.739335	0.613226	0.739335	0.649879	0.917589
2	0.832609	0.685389	0.659458	0.685389	0.658029	0.869029
3	0.804348	0.762544	0.592481	0.762544	0.643290	0.918121
4	0.817391	0.760108	0.613177	0.760108	0.662467	0.919567
5	0.813043	0.724126	0.603037	0.724126	0.646180	0.909981
Rata-rata	0.809227	0.734301	0.616276	0.734301	0.651969	0.906462

4.4 Evaluasi Model

Evaluasi model dilakukan menggunakan *confusion matrix* dan metrik evaluasi *Accuracy*, *Balanced Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *ROC-AUC*. *Confusion matrix* untuk masing-masing model bisa dilihat pada Gambar 4.1 dan 4.2.

Gambar 4.1 *Confusion matrix Random Forest*

Berdasarkan Gambar 4.1, model *Random Forest* mampu mengklasifikasikan kelas Baik dengan sangat baik, yaitu sebanyak 1.813 data (95,98%) berhasil diprediksi dengan benar. Sebaliknya, performa model pada kelas minoritas masih relatif rendah. Pada kelas Kurang Baik, hanya 173 data (52,91%) yang berhasil diklasifikasikan dengan benar, sedangkan 150 data (45,87%) masih salah diprediksi sebagai kelas Baik. Sementara itu, pada kelas Rusak Berat, model hanya mampu mengklasifikasikan 26 data (30,59%) dengan benar, dengan sebagian besar kesalahan berupa 43 data (50,59%) yang diprediksi sebagai kelas Baik dan 16 data (18,82%) sebagai kelas Kurang Baik. Hasil tersebut menunjukkan bahwa model *Random Forest* cenderung memberikan prediksi pada kelas mayoritas akibat ketidakseimbangan distribusi data.

Gambar 4.2 *Confusion matrix Random Forest + SMOTE*

Berdasarkan Gambar 4.2, penerapan SMOTE meningkatkan kemampuan model dalam mengenali kelas minoritas dibandingkan model *Random Forest* tanpa SMOTE. Pada kelas Baik, model berhasil mengklasifikasikan 1.570 data (83,11%) dengan benar. Meskipun nilai ini lebih rendah dibandingkan model tanpa SMOTE, performa pada kelas minoritas mengalami peningkatan yang signifikan. Jumlah prediksi benar pada kelas Kurang Baik meningkat menjadi 237 data (72,48%), sedangkan pada kelas Rusak Berat meningkat menjadi 55 data (64,71%). Selain itu, kesalahan prediksi kelas Kurang Baik dan Rusak Berat sebagai kelas Baik juga menurun masing-masing menjadi 74 data (22,63%) dan 17 data (20,00%).

Secara keseluruhan, penerapan SMOTE meningkatkan tingkat klasifikasi benar pada kelas Kurang Baik dari 52,91% menjadi 72,48% dan pada kelas Rusak Berat dari 30,59% menjadi 64,71%, meskipun tingkat klasifikasi benar pada kelas Baik menurun dari 95,98% menjadi 83,11%. Hasil tersebut menunjukkan adanya *trade-off*, yaitu model mengurangi dominasi prediksi pada kelas mayoritas untuk menghasilkan kemampuan klasifikasi yang lebih seimbang pada seluruh kelas, khususnya kelas minoritas yang menjadi fokus penelitian. Perbandingan hasil evaluasi model antara model *Random Forest* dan model *Random Forest* + SMOTE bisa dilihat pada Tabel 4.22.

Tabel 4.22 Perbandingan hasil evaluasi model RF dengan RF + SMOTE

Metrik Evaluasi	RF	RF + SMOTE
Accuracy	0.874403	0.809227
Balanced Accuracy	0.598216	0.734301
Precision	0.735064	0.616276
Recall	0.598216	0.734301
F1-Score	0.638434	0.651969
ROC-AUC	0.919312	0.906462

Berdasarkan Tabel 4.22, model *Random Forest* tanpa SMOTE memperoleh nilai *Accuracy* sebesar 87,44%, sedangkan model *Random Forest* dengan SMOTE memperoleh *Accuracy* sebesar 80,92%. Meskipun *Accuracy* menurun, metrik ini tidak dapat dijadikan satu-satunya acuan karena dataset penelitian memiliki distribusi kelas yang tidak seimbang. Penerapan SMOTE meningkatkan nilai *Balanced Accuracy* dan *Recall* (59,82% menjadi 73,43%)

dan *F1-score* (63,84% menjadi 65,20%), yang menunjukkan bahwa model menjadi lebih mampu mengenali seluruh kelas, khususnya kelas minoritas. Namun nilai *Precision* menurun (73,51% menjadi 61,63%), serta ROC-AUC sedikit menurun (91,93% menjadi 90,64%). Walaupun demikian, kedua model masih memiliki kemampuan diskriminasi yang sangat baik karena nilai ROC-AUC berada di atas 0,90.

Secara keseluruhan, model *Random Forest* dengan SMOTE dipilih sebagai model terbaik karena mampu menghasilkan performa klasifikasi yang lebih seimbang. Penurunan *Accuracy*, *Precision*, dan ROC-AUC merupakan konsekuensi dari meningkatnya sensitivitas model terhadap kelas minoritas setelah penerapan SMOTE. Dalam konteks penelitian ini, kemampuan mendeteksi inventaris yang berada pada kondisi Kurang Baik dan Rusak Berat lebih penting dibandingkan memperoleh *Accuracy* yang tinggi pada kelas mayoritas.

Selain meningkatkan kemampuan model dalam mengenali kelas minoritas, penerapan *Random Forest* dengan SMOTE juga memberikan dampak terhadap efisiensi proses pengelolaan inventaris. Proses klasifikasi yang sebelumnya bergantung pada penilaian manual dapat dilakukan secara lebih konsisten karena seluruh inventaris dievaluasi menggunakan aturan yang sama berdasarkan karakteristik data. Dengan demikian, hasil klasifikasi dapat dimanfaatkan sebagai dasar dalam menentukan prioritas pemeliharaan secara lebih terarah dan berbasis data.

4.5 Analisis Performa Model Berdasarkan Kelas

Selain dievaluasi secara keseluruhan, performa model juga dianalisis pada setiap kelas menggunakan nilai *Precision*, *Recall*, dan *F1-score*. Hasil evaluasi per kelas menunjukkan bahwa penerapan SMOTE memberikan pengaruh yang berbeda terhadap masing-masing kelas kondisi inventaris. Tabel evaluasi per kelas pada model *Random Forest* dapat dilihat pada Tabel 4.23 dan *Random Forest* + SMOTE pada Tabel 4.24

Tabel 4.23 Evaluasi model per kelas (*Random Forest*)

Kelas Kondisi	Precision	Recall	F1-Score
Baik	0.903789	0.959767	0.930937
Kurang Baik	0.692000	0.529052	0.599653
Rusak Berat	0.577778	0.305882	0.400000

Tabel 4.24 Evaluasi model per kelas (*Random Forest* + SMOTE)

Kelas Kondisi	Precision	Recall	F1-Score
Baik	0.945214	0.831128	0.884507
Kurang Baik	0.467456	0.724771	0.568345
Rusak Berat	0.413534	0.647059	0.504587

Pada kelas Baik, model *Random Forest* tanpa SMOTE memperoleh *Precision* sebesar 90,38%, *Recall* sebesar 95,98%, dan *F1-score* sebesar 93,09%. Setelah penerapan SMOTE, *Precision* meningkat menjadi 94,52%, namun *Recall* menurun menjadi 83,11%, sehingga *F1-score* juga menurun menjadi 88,45%. Hasil tersebut menunjukkan bahwa model menjadi lebih selektif dalam memberikan prediksi pada kelas Baik, tetapi tidak lagi terlalu mendominasi prediksi terhadap kelas mayoritas.

Pada kelas Kurang Baik, penerapan SMOTE meningkatkan kemampuan model dalam mengenali data yang sebenarnya termasuk kelas Kurang Baik. Hal ini ditunjukkan oleh peningkatan nilai *Recall* dari 52,91% menjadi 72,48%. Namun demikian, nilai *Precision* menurun dari 69,20% menjadi 46,75%, sehingga *F1-score* sedikit menurun dari 59,97% menjadi 56,83%. Kondisi tersebut menunjukkan bahwa model berhasil menemukan lebih banyak data Kurang Baik meskipun disertai peningkatan prediksi positif yang kurang tepat.

Pada kelas Rusak Berat, peningkatan performa terlihat lebih signifikan. Nilai *Recall* meningkat dari 30,59% menjadi 64,71%, sedangkan *F1-score* meningkat dari 40,00% menjadi 50,46%. Meskipun nilai *Precision* menurun dari 57,78% menjadi 41,35%, peningkatan *Recall* menunjukkan bahwa model menjadi lebih mampu mendeteksi inventaris dengan kondisi Rusak Berat yang sebelumnya banyak terklasifikasi sebagai kelas Baik.

Secara keseluruhan, penerapan SMOTE menghasilkan *trade-off* antara *Precision* dan *Recall*. Model menjadi lebih mampu mengenali kelas minoritas, khususnya Kurang Baik dan Rusak Berat, meskipun terjadi penurunan *Precision*

pada kedua kelas tersebut. Mengingat tujuan penelitian adalah mendukung identifikasi inventaris yang memerlukan pemeliharaan, peningkatan kemampuan deteksi terhadap kelas minoritas lebih penting dibandingkan mempertahankan dominasi prediksi pada kelas mayoritas. Oleh karena itu, model *Random Forest* dengan SMOTE dinilai lebih sesuai untuk mendukung pengambilan keputusan pemeliharaan inventaris nonmedis.

4.6 Analisis *Feature Importance*

Analisis *feature importance* dilakukan untuk mengetahui tingkat kontribusi masing-masing variabel dalam proses klasifikasi kondisi inventaris menggunakan algoritma *Random Forest*. Hasil analisis *feature importance* dapat dilihat pada Tabel 4.25.

Tabel 4.25 Hasil analisis *feature importance*

Fitur	Importance
depresiasi aset	0.291345
umur	0.240536
harga per unit	0.221862
kategori	0.138508
bahan	0.107748

Variabel depresiasi aset memiliki nilai *feature importance* tertinggi sebesar 29,13%, sehingga menjadi variabel yang paling berpengaruh dalam membedakan kondisi inventaris. Hal ini menunjukkan bahwa penurunan nilai ekonomis aset, yang dipengaruhi oleh harga per unit, umur, dan masa manfaat, merupakan indikator utama dalam menentukan kondisi suatu barang.

Variabel umur menempati urutan kedua dengan nilai 24,05%, yang mengindikasikan bahwa semakin lama inventaris digunakan, semakin besar kemungkinan terjadi penurunan kualitas akibat keausan dan penggunaan secara terus-menerus. Selanjutnya, variabel harga per unit memperoleh nilai 22,18%, menunjukkan bahwa nilai ekonomis setiap unit inventaris turut membantu model membedakan kondisi barang karena berkaitan dengan kualitas, spesifikasi, dan kebutuhan pemeliharaan.

Sementara itu, variabel kategori memiliki nilai *feature importance* sebesar 13,85%, yang menunjukkan bahwa perbedaan karakteristik penggunaan dan pola

kerusakan pada setiap jenis inventaris turut memengaruhi proses klasifikasi. Adapun variabel bahan memiliki nilai *feature importance* terendah, yaitu 10,77%. Meskipun tetap berkontribusi terhadap model, pengaruhnya relatif lebih kecil karena jenis material penyusun inventaris tidak secara langsung menentukan kondisi barang. Inventaris dengan bahan yang sama masih dapat memiliki kondisi yang berbeda bergantung pada umur penggunaan, tingkat depresiasi aset, nilai ekonomis, dan kategorinya.

Hasil analisis *feature importance* menunjukkan bahwa model *Random Forest* lebih banyak memanfaatkan variabel numerik yang merepresentasikan usia dan nilai ekonomis inventaris dibandingkan variabel kategorik. Hal ini mengindikasikan bahwa kondisi inventaris lebih dipengaruhi oleh lamanya penggunaan dan tingkat penurunan nilai aset daripada karakteristik material penyusunnya. Dengan demikian, variabel hasil *feature engineering*, khususnya depresiasi aset, terbukti memberikan kontribusi terbesar dalam meningkatkan kemampuan model membedakan kondisi inventaris.

4.7 Implementasi *Dashboard*

Dashboard dikembangkan menggunakan bahasa pemrograman Python dengan *framework* Streamlit sebagai implementasi model *Random Forest* berbasis SMOTE yang telah dibangun. *Dashboard* berfungsi sebagai *proof of concept* yang memungkinkan pengguna melakukan klasifikasi kondisi inventaris nonmedis melalui antarmuka yang sederhana tanpa perlu memahami proses *machine learning* secara langsung.

Seluruh proses dilakukan secara lokal sesuai dengan batasan penelitian sehingga *dashboard* hanya digunakan sebagai media visualisasi dan penunjang pengambilan keputusan. Berikut merupakan halaman-halaman *dashboard* yang telah dibuat.

4.7.1 Halaman Beranda

Halaman beranda berfungsi untuk membantu pengguna memahami alur penggunaan *dashboard* sebelum melakukan proses analisis.

4.7.2 Halaman Unggah

Halaman unggah digunakan untuk memasukkan dataset inventaris nonmedis dalam format *Comma Separated Value* (CSV). Dataset yang diunggah merupakan data *raw* dengan atribut nama barang, bahan, kategori, tahun pembelian, jumlah, dan harga. Setelah *file* berhasil diunggah, *dashboard* melakukan *preprocessing* secara otomatis.

4.7.3 Halaman Overview

Halaman *overview* menampilkan ringkasan data sesudah *preprocessing*. Informasi yang ditampilkan meliputi jumlah data, statistik sederhana, serta visualisasi distribusi atribut. Halaman ini membantu pengguna memahami karakteristik data yang sudah diinputkan.

4.7.4 Halaman Prediksi

Halaman prediksi menampilkan hasil klasifikasi kondisi barang menggunakan model *Random Forest* + SMOTE. *Dashboard* menyajikan ringkasan jumlah barang pada setiap kelas, distribusi hasil prediksi, serta tabel hasil klasifikasi.

4.7.5 Halaman Pemeliharaan

Halaman pemeliharaan mengubah hasil klasifikasi menjadi rekomendasi tindakan pemeliharaan. Barang dikelompokkan ke dalam prioritas tinggi, sedang, dan rendah berdasarkan kondisi hasil prediksi sehingga dapat membantu pihak rumah sakit menentukan urutan tindakan pemeliharaan secara lebih terarah.

Implementasi *dashboard* sebagai *proof of concept* menunjukkan bahwa proses klasifikasi kondisi inventaris dapat dilakukan secara lebih sederhana melalui satu aplikasi yang terintegrasi. *Dashboard* memungkinkan pengguna mengunggah data inventaris, melakukan *preprocessing* secara otomatis, memperoleh hasil klasifikasi, serta melihat rekomendasi prioritas pemeliharaan

tanpa harus melakukan analisis secara manual. Dengan adanya proses tersebut, pengambilan keputusan menjadi lebih konsisten, objektif, dan terarah karena didasarkan pada hasil klasifikasi model, sehingga mendukung efisiensi pengelolaan inventaris nonmedis di lingkungan rumah sakit.

4.8 Analisis Hasil Klasifikasi

Setelah model berhasil diimplementasikan pada *dashboard* interaktif, dilakukan analisis terhadap hasil klasifikasi. Analisis dilakukan dengan membandingkan prediksi model dengan kondisi inventaris pada dataset asli sebagai *ground truth*. Perbandingan tersebut bertujuan untuk mengevaluasi tingkat kesesuaian hasil prediksi model serta menunjukkan kemampuan *dashboard* dalam mengimplementasikan model klasifikasi. Perbandingan hasil klasifikasi dilakukan terhadap dua ruangan yaitu Melati Bawah dan Seruni (dipilih secara acak). Perbandingan dapat dilihat pada Tabel 4.26 dan Tabel 4.27.

Tabel 4.26 Perbandingan hasil klasifikasi (Melati Bawah)

Ruangan	Baik	Kurang Baik	Rusak Berat
Melati Bawah (<i>Dashboard</i>)	47	0	2
Melati Bawah (<i>Real</i>)	38	9	2
Tingkat Kesesuaian	81,63%		

Tabel 4.27 Perbandingan hasil klasifikasi (Seruni)

Ruangan	Baik	Kurang Baik	Rusak Berat
Seruni (<i>Dashboard</i>)	36	3	3
Seruni (<i>Real</i>)	39	3	0
Tingkat Kesesuaian	93,33%		

Berdasarkan Tabel 4.26 dan Tabel 4.27, hasil klasifikasi *dashboard* memiliki tingkat kesesuaian yang cukup baik dengan data kondisi inventaris sebenarnya. Sebagian besar inventaris berhasil diklasifikasikan sesuai dengan kondisi asli, meskipun masih terdapat beberapa perbedaan pada kelas Baik, Kurang Baik, dan Rusak Berat akibat kesalahan prediksi model. Perbedaan tersebut menunjukkan bahwa model belum mampu mengklasifikasikan seluruh data secara sempurna, namun secara keseluruhan *dashboard* telah berhasil mengimplementasikan model *Random Forest* dengan SMOTE dan menghasilkan klasifikasi yang dapat digunakan sebagai dasar dalam menentukan prioritas pemeliharaan inventaris.

BAB 5. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat diambil beberapa kesimpulan sebagai berikut.

1. Algoritma *Random Forest* dengan SMOTE berhasil diterapkan untuk mengklasifikasikan kondisi inventaris nonmedis ruang rawat inap kelas 3 RSD dr. Soebandi menggunakan lima variabel, yaitu bahan, kategori, umur, harga per unit, dan depresiasi aset. Implementasi model pada *dashboard* interaktif menunjukkan bahwa hasil klasifikasi memiliki tingkat kesesuaian yang baik dengan kondisi inventaris pada data asli, meskipun masih terdapat beberapa perbedaan prediksi pada kelas Baik, Kurang Baik, dan Rusak Berat. Hasil tersebut menunjukkan bahwa model mampu mengidentifikasi kondisi inventaris secara konsisten dan dapat digunakan sebagai pendukung pengambilan keputusan pemeliharaan inventaris nonmedis. Berdasarkan analisis *feature importance*, variabel depresiasi aset memberikan kontribusi terbesar terhadap proses klasifikasi (29,13%), diikuti oleh umur (24,05%), harga per unit (22,18%), kategori (13,85%), dan bahan (10,77%), yang menunjukkan bahwa kondisi inventaris lebih banyak dipengaruhi oleh faktor usia dan penurunan nilai ekonomis dibandingkan karakteristik material penyusunnya.
2. Hasil evaluasi menunjukkan bahwa penerapan SMOTE mampu meningkatkan kemampuan model dalam mengenali kelas minoritas sehingga menghasilkan performa klasifikasi yang lebih seimbang. Peningkatan tersebut ditunjukkan oleh kenaikan nilai *Balanced Accuracy* dan *Recall* dari 59,82% menjadi 73,43%, serta peningkatan tingkat klasifikasi benar pada kelas Kurang Baik dari 52,91% menjadi 72,48% dan kelas Rusak Berat dari 30,59% menjadi 64,71%. Analisis performa per kelas juga menunjukkan bahwa penerapan SMOTE meningkatkan kemampuan model dalam mendeteksi inventaris pada kelas minoritas meskipun terjadi penurunan *Precision* pada kedua kelas tersebut sebagai

konsekuensi meningkatnya sensitivitas model. Dengan demikian, *Random Forest* dengan SMOTE dipilih sebagai model terbaik karena lebih sesuai untuk mendukung identifikasi inventaris yang memerlukan pemeliharaan dibandingkan model tanpa SMOTE.

3. *Dashboard* interaktif berbasis Streamlit berhasil dikembangkan sebagai *proof of concept* implementasi model klasifikasi. *Dashboard* mampu melakukan *preprocessing* data secara otomatis, menampilkan hasil prediksi kondisi inventaris, visualisasi distribusi hasil klasifikasi, serta menghasilkan rekomendasi prioritas pemeliharaan berdasarkan hasil prediksi. Selain mempermudah visualisasi hasil analisis, *dashboard* juga mendukung proses pengambilan keputusan yang lebih konsisten, objektif, dan terarah dibandingkan penilaian manual sehingga dapat meningkatkan efisiensi pengelolaan inventaris nonmedis.

5.2 Saran

Berdasarkan hasil penelitian, beberapa saran yang dapat diberikan adalah sebagai berikut.

1. Penelitian selanjutnya disarankan menggunakan data dengan cakupan periode dan unit rumah sakit yang lebih luas agar model memiliki kemampuan generalisasi yang lebih baik.
2. Pengembangan model dapat dilakukan dengan membandingkan *Random Forest* terhadap algoritma lain atau melakukan optimasi *hyperparameter* untuk meningkatkan performa klasifikasi.
3. *Dashboard* dapat dikembangkan lebih lanjut dengan mengintegrasikannya ke sistem informasi rumah sakit serta menambahkan fitur *monitoring* kondisi inventaris secara berkala, notifikasi prioritas pemeliharaan, dan pembaruan data secara otomatis sehingga proses pengambilan keputusan pemeliharaan dapat dilakukan secara lebih cepat, konsisten, dan berkelanjutan.

DAFTAR PUSTAKA

- Akhmadi, L. A. (2015). *Rancang bangun aplikasi manajemen aset tetap pada Rumah Sakit Islam Jemursari Surabaya* [Skripsi, Universitas Dinamika STIKOM Surabaya]. Repositori Universitas Dinamika <https://repository.dinamika.ac.id/id/eprint/1596/>
- Andi. (2023, Agustus 14). Memahami dan menerapkan matriks evaluasi ROC-AUC dalam machine learning. *Medium*. <https://medium.com/@andimrinaldisaputraa/memahami-dan-menerapkan-matriks-evaluasi-roc-auc-dalam-machine-learning-4468e5fcb9a>
- Anggraini, N., Seswanto, H. J., & Yani, A. (2023). Analisis penerapan metode penyusutan aset tetap dan revaluasi aset tetap serta pengaruhnya terhadap laporan keuangan. *JCA (Jurnal Cendekia Akuntansi)*, 4(2), 46. <https://doi.org/10.32503/akuntansi.v4i2.4400>
- Assegie, T. A., Salau, A. O., Chhabra, G., Kaushik, K., & Braide, S. L. (2024). Evaluation of random forest and support vector machine models in educational data mining. *Proceedings of the 2nd International Conference on Advancement in Computation and Computer Technologies (InCACCT 2024)*, 131–135. <https://doi.org/10.1109/InCACCT61598.2024.10551110>
- Boyrotan, A. U., & Maryoso, S. (2020). Penerapan metode depresiasi aktiva tetap pada PT ANTAM Tbk. *Ekonomi Bisnis*, 26(1), 187–197. <https://doi.org/10.33592/jeb.v26i1.618>
- Denny Laksmiana, R., & Adriansyah. (2024). Faktor-faktor yang mempengaruhi pilihan metode depresiasi di perusahaan: Studi kasus pada sektor manufaktur. *Accounting Information System, Taxes, and Auditing*, 3(2), 51-56. <https://akuntansi.pnp.ac.id/aista>
- Durmuş, A., Aydın, Ö., & Dalkılıç, F. (2025). Optimizing healthcare inventory management using machine learning for efficient classification of medical supplies. *OPSEARCH*. <https://doi.org/10.1007/s12597-025-01004-x>
- Erlin, Desnelita, Y., Nasution, N., Suryati, L., & Zoromi, F. (2022). Dampak SMOTE terhadap kinerja random forest classifier berdasarkan data tidak

- seimbang. *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 21(3), 677–690. <https://doi.org/10.30812/matrik.v21i3.1726>
- Farhan, R. (2021, Juni 15). Mengenal resampling dan imbalanced dataset. *Medium*. <https://rusnandafarhan.medium.com/resampling-untuk-permasalahan-imbalanced-dataset-5d9ade919cc5>
- Géron, A. (2023). *Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow*. Sebastopol: O'Reilly Media.
- Harefa, I., & Hulu, T. H. S. (2022). Analisis penyusutan aktiva tetap dan pengaruhnya terhadap laporan keuangan. *Jurnal Akuntansi, Manajemen dan Ekonomi*, 1(1), 146–151. <https://doi.org/10.56248/jamane.v1i1.25>
- Jackins, V., Vimal, S., Kaliappan, M., & Lee, M. Y. (2021). AI-based smart prediction of clinical disease using random forest classifier and Naive Bayes. *Journal of Supercomputing*, 77(5), 5198–5219. <https://doi.org/10.1007/s11227-020-03481-x>
- Lomash Bhuva. (2025, Maret 20). Understanding feature importance in machine learning. *Medium*. <https://medium.com/@lomashbhuva/understanding-feature-importance-in-machine-learning-d86ec50e0055>
- Maleki Varnosfaderani, S., & Forouzanfar, M. (2024). The role of AI in hospitals and clinics: Transforming healthcare in the 21st century. *Bioengineering*, 11(4). <https://doi.org/10.3390/bioengineering11040337>
- Mulyana, Y., Rc, J., Aryati, N., Sanmarino, A., Bhayangkara, R. S., & Hasan, M. (2023). Sistem informasi logistik non medis pada Rumah Sakit Bhayangkara Palembang. *Jurnal Sistem Informasi dan Teknik Informatika*, 1(1), 1–9.
- Nuril Izza, S., & Muzid, S. (2025). Implementasi sistem informasi pengelolaan inventaris barang non medis pada RS Aisyiyah Kudus. *Abdifomatika: Jurnal Pengabdian Masyarakat Informatika*, 5(1), 40–51. <https://doi.org/10.59395/abdifomatika.v5i1.260>
- Pal, M., & Parija, S. (2021). Prediction of heart diseases using random forest. *Journal of Physics: Conference Series*, 1817(1). <https://doi.org/10.1088/1742-6596/1817/1/012009>

- Ratwani, R., Adams, K., Kim, T., Busog, D.-N., Howe, J., Jones, R., & Krevat, S. (2023). Assessing equipment, supplies, and devices for patient safety issues. *Patient Safety*, 15–25. <https://doi.org/10.33940/data/2023.3.2>
- Rina. (2023a, Juni 21). Berbagai metode validasi model klasifikasi machine learning yang wajib diketahui (Part 1). *Medium*. <https://esairina.medium.com/berbagai-metode-validasi-model-klasifikasi-machine-learning-yang-wajib-diketahui-part-1-bb0dd3c694ba>
- Rina. (2023b, Juni 22). Memahami confusion matrix: Accuracy, precision, recall, specificity, dan F1-score untuk evaluasi model klasifikasi. *Medium*. <https://esairina.medium.com/memahami-confusion-matrix-accuracy-precision-recall-specificity-dan-f1-score-610d4f0db7cf>
- Satrio Junaidi, Valicia Anggela, R., & Kariman, D. (2024). Klasifikasi metode data mining untuk prediksi kelulusan tepat waktu mahasiswa dengan algoritma Naïve Bayes, Random Forest, Support Vector Machine (SVM), dan Artificial Neural Network (ANN). *Journal of Applied Computer Science and Technology*, 5(1), 109–119. <https://doi.org/10.52158/jacost.v5i1.489>
- Setiawan, R. (2021, Oktober 29). Apa itu data mining dan bagaimana metodenya? *Dicoding Blog*. <https://www.dicoding.com/blog/apa-itu-data-mining/>
- Sugiyono. (2019). *Metode Penelitian Kuantitatif, Kualitatif, dan R&D*. Bandung: Alfabeta.
- Ward, T., Jenab, K., Ortega-Moody, J., & Staub, S. (2024). A comprehensive review of machine learning techniques for condition-based maintenance. *International Journal of Prognostics and Health Management*, 15(2). <https://doi.org/10.36001/ijphm.2024.v15i2.3850>
- Wongvorachan, T., He, S., & Bulut, O. (2023). A comparison of undersampling, oversampling, and SMOTE methods for dealing with imbalanced classification in educational data mining. *Information*, 14(1). <https://doi.org/10.3390/info14010054>
- Zach. (2021, Oktober 6). What is balanced accuracy? (Definition & Example). *Statology*. <https://www.statology.org/balanced-accuracy/>

LAMPIRAN

Lampiran 1.1 Hasil wawancara prapenelitian



Lampiran 3.1 Data inventaris nonmedis ruang rawat inap kelas 3



Lampiran 4.1 Dataset inventaris nonmedis ruang rawat inap kelas 3



Lampiran 4.2 Kode pemahaman dataset



Lampiran 4.3 Kode *preprocessing* dataset



Lampiran 4.4 Kode pembangunan model *Random Forest*



Lampiran 4.5 Kode pembangunan model *Random Forest + SMOTE*



Lampiran 4.6 Kode analisis dan evaluasi model



Lampiran 4.7 Kode pembangunan *dashboard* interaktif



Lampiran 4.8 Tampilan *dashboard* interaktif

