



Peningkatan Akurasi Prediksi Stok Bahan Baku Furnitur Menggunakan Algoritma Random Forest Regressor Berbasis Web

Ahmad Nafi'uzzahidi*, Gentur Wahyu Nyipto Wibowo, Sarwido

Fakultas Sains dan Teknologi, Teknik Informatika, Universitas Islam Nahdlatul Ulama Jepara, Jepara
Jl. Taman Siswa, Pekeng, Kauman, Tahunan, Kec. Tahunan, Kabupaten Jepara, Jawa Tengah, Indonesia

Email: ^{1,*}nafiuzzahidi110@gmail.com, ²gentur@unisnu.ac.id, ³sarwido.unisnu@gmail.com

Email Penulis Korespondensi: nafiuzzahidi110@gmail.com

Submitted: 03/01/2026; Accepted: 21/01/2026; Published: 21/01/2026

Abstrak—Penelitian ini bertujuan untuk mengatasi permasalahan ketidakpastian persediaan bahan baku pada industri furnitur melalui implementasi algoritma machine learning Random Forest Regressor. Masalah utama yang diangkat adalah fluktuasi permintaan yang sering kali menyebabkan ketidakefisienan manajemen stok, baik berupa kelebihan persediaan maupun kekurangan bahan produksi yang menghambat proses manufaktur. Metode penelitian yang digunakan adalah pendekatan kuantitatif dengan desain eksperimental pengembangan sistem berbasis web menggunakan kerangka kerja Flask dan basis data MySQL. Sampel data mencakup catatan historis transaksi penjualan dan data Bill of Materials (BOM) dari produk furnitur seperti meja makan dan kursi minimalis. Sebelum pemodelan, data melalui tahapan preprocessing yang meliputi pembersihan data (data cleaning), penanganan missing values, serta normalisasi untuk meminimalkan dampak noise pada data transaksi. Pengumpulan data dilakukan melalui ekstraksi basis data internal yang kemudian diolah melalui tahap feature engineering berdasarkan tren waktu. Hasil penelitian menunjukkan bahwa model Random Forest mampu memprediksi kebutuhan bahan baku masa depan dengan tingkat akurasi yang tinggi, yang dibuktikan dengan nilai koefisien determinasi (R^2) sebesar 0,84 dan Mean Absolute Error (MAE) sebesar 5,4. Temuan ini membuktikan bahwa pendekatan berbasis data mampu memberikan estimasi kebutuhan stok yang lebih presisi dibandingkan metode konvensional. Kesimpulannya, integrasi teknologi prediksi ini memberikan kontribusi praktis dalam mempercepat pengambilan keputusan manajerial dan mengoptimalkan efisiensi operasional pada sektor manufaktur menengah. Implikasi penelitian ini mendukung pengembangan teori sistem pendukung keputusan berbasis kecerdasan buatan dalam manajemen rantai pasok.

Kata Kunci: Random Forest; Prediksi Stok; Manajemen Bahan Baku; Industri Furnitur; Machine Learning.

Abstract—This study aims to address the uncertainty of raw material inventory in the furniture industry through the implementation of the Random Forest Regressor machine learning algorithm. The primary problem addressed is demand fluctuation, which frequently leads to stock management inefficiencies, including overstocking or material shortages that disrupt production processes. The research method employs a quantitative approach with an experimental design, developing a web-based system using the Flask framework and MySQL database. The data sample includes historical sales transaction records and Bill of Materials (BOM) data for furniture products, such as dining tables and minimalist chairs. Prior to modeling, the data underwent a preprocessing stage comprising data cleaning, handling missing values, and normalization to minimize the impact of noise on transaction data. Data collection was conducted through the extraction of internal databases, which were then processed through feature engineering stages based on temporal trends. The results demonstrate that the Random Forest model can predict future raw material requirements with high accuracy, evidenced by a coefficient of determination (R^2) of 0.84 and a Mean Absolute Error (MAE) of 5.4. These findings prove that a data-driven approach provides more precise stock requirement estimations than conventional methods. In conclusion, the integration of this predictive technology offers practical contributions to accelerating managerial decision-making and optimizing operational efficiency in the medium-scale manufacturing sector. The implications of this study support the theoretical development of artificial intelligence-based decision support systems in supply chain management.

Keywords: Random Forest; Stock Prediction; Raw Material Management; Furniture Industry; Machine Learning.

1. PENDAHULUAN

Industri furnitur berbasis kayu merupakan salah satu sektor manufaktur yang memiliki peran strategis dalam mendukung perekonomian, khususnya pada skala usaha kecil dan menengah. Karakteristik industri ini ditandai oleh tingginya variasi produk, fluktuasi permintaan, serta ketergantungan yang besar terhadap ketersediaan bahan baku kayu sebagai komponen utama produksi. Ketidaktepatan dalam perencanaan kebutuhan bahan baku dapat menyebabkan berbagai permasalahan operasional, seperti kelebihan persediaan yang meningkatkan biaya penyimpanan atau kekurangan bahan yang menghambat proses produksi dan menurunkan tingkat pelayanan kepada pelanggan [1].

Seiring berkembangnya teknologi informasi, pendekatan berbasis data (data-driven decision making) menjadi solusi yang semakin relevan dalam mendukung pengambilan keputusan produksi [2]. Pemanfaatan data historis produksi dan penjualan memungkinkan perusahaan untuk melakukan prediksi kebutuhan bahan baku secara lebih objektif dan terukur dibandingkan metode konvensional berbasis intuisi atau pengalaman semata. Namun, pada praktiknya, banyak pelaku industri furnitur masih mengandalkan pendekatan manual dalam menentukan jumlah bahan baku, sehingga akurasi perencanaan cenderung rendah dan sulit beradaptasi terhadap perubahan pola permintaan [3].

Berbagai penelitian terdahulu telah mengkaji penerapan metode komputasional untuk peramalan permintaan dan perencanaan material. Metode statistik klasik seperti regresi linier dan moving average relatif mudah diimplementasikan, tetapi memiliki keterbatasan dalam menangkap pola data yang bersifat nonlinier dan kompleks [4]. Dalam beberapa tahun terakhir, pendekatan machine learning mulai banyak digunakan karena kemampuannya dalam mengenali pola tersembunyi pada data multivariat. Studi oleh Raju et al. [5] dan Gómez-Rocha et al. [6] Park et al.[7] menunjukkan bahwa algoritma pembelajaran mesin mampu meningkatkan akurasi prediksi dibandingkan metode tradisional. Meskipun demikian, sebagian besar penelitian tersebut masih berfokus pada industri manufaktur berskala besar atau pada data produksi massal yang relatif stabil.

Salah satu algoritma machine learning yang banyak digunakan dalam konteks prediksi kuantitatif adalah Random Forest Regressor. Algoritma ini merupakan bagian dari metode ensemble learning yang menggabungkan sejumlah pohon keputusan untuk menghasilkan prediksi yang lebih stabil dan robust terhadap noise pada data[8]. Keunggulan utama Random Forest terletak pada kemampuannya menangani hubungan nonlinier antarvariabel, mengurangi risiko overfitting, serta mempertahankan performa yang baik pada dataset dengan jumlah fitur yang relatif banyak [9]. Beberapa penelitian menunjukkan bahwa Random Forest Regressor memberikan hasil yang lebih konsisten dalam peramalan kebutuhan material dibandingkan algoritma regresi tunggal [10].


Meskipun demikian, masih terdapat kesenjangan penelitian yang signifikan, khususnya pada penerapan Random Forest Regressor dalam konteks industri furnitur berbasis (custom furniture). Industri ini memiliki karakteristik permintaan yang tidak stabil dan sangat bergantung pada spesifikasi unik dari setiap pelanggan. Kompleksitas prediksi pada sektor ini dipengaruhi oleh beragam variabel (fitur) yang dinamis, seperti perbedaan jenis kayu yang digunakan, dimensi produk yang bervariasi (panjang, lebar, tebal), hingga pengaruh tren penjualan musiman. Akibatnya, pola penggunaan bahan baku cenderung menjadi non-linear dan sulit diestimasi secara akurat jika hanya menggunakan metode peramalan tradisional. Penelitian yang secara khusus mengintegrasikan algoritma Random Forest ke dalam sistem prediksi kebutuhan bahan baku pada industri furnitur skala menengah masih terbatas, terutama yang disertai dengan implementasi sistem berbasis web yang aplikatif [11].

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan sistem prediksi kebutuhan bahan baku kayu menggunakan metode Random Forest Regressor berbasis web pada Kajava Furniture. Sistem yang dikembangkan diharapkan mampu memberikan estimasi kebutuhan bahan baku yang lebih akurat berdasarkan data historis produksi, sehingga dapat mendukung perencanaan persediaan dan pengambilan keputusan produksi secara lebih efektif. Kontribusi utama penelitian ini terletak pada penerapan empiris algoritma Random Forest Regressor dalam lingkungan industri furnitur nyata, serta penyediaan solusi prediktif yang aplikatif dan sesuai dengan kebutuhan usaha furnitur skala menengah.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan jenis penelitian prediktif, yang bertujuan untuk mengembangkan model estimasi kebutuhan bahan baku kayu berdasarkan data historis produksi. Pendekatan kuantitatif dipilih karena memungkinkan pengukuran hubungan antarvariabel secara objektif serta evaluasi kinerja model prediksi menggunakan indikator statistik yang terukur [12]. Metode machine learning digunakan sebagai pendekatan utama karena kemampuannya dalam menangani pola data yang kompleks dan bersifat nonlinier[13].



Gambar 1. Metode machine learning

Evaluasi kinerja model dilakukan menggunakan koefisien determinasi (R^2) serta nilai galat prediksi seperti MAE. Koefisien determinasi digunakan untuk mengukur proporsi variasi kebutuhan bahan baku kayu yang dapat dijelaskan oleh model, sedangkan MAE digunakan untuk mengetahui besarnya kesalahan prediksi secara absolut. Alur penerapan metode Random Forest Regressor dalam penelitian ini ditunjukkan pada Gambar 1.

Tahapan penelitian diawali dengan identifikasi permasalahan yang berkaitan dengan ketidaktepatan perencanaan kebutuhan bahan baku pada industri furnitur. Selanjutnya dilakukan pengumpulan data historis produksi dan penggunaan bahan baku kayu yang diperoleh dari catatan internal Kajava Furniture. Data yang terkumpul kemudian melalui proses data preprocessing yang meliputi pembersihan data (data cleaning), penanganan data hilang, serta normalisasi untuk memastikan kualitas data sebelum digunakan dalam pemodelan. Tahap berikutnya adalah pemilihan fitur yang relevan, yang bertujuan untuk meningkatkan kinerja model prediksi dengan mengurangi variabel yang tidak berkontribusi signifikan terhadap hasil prediksi.

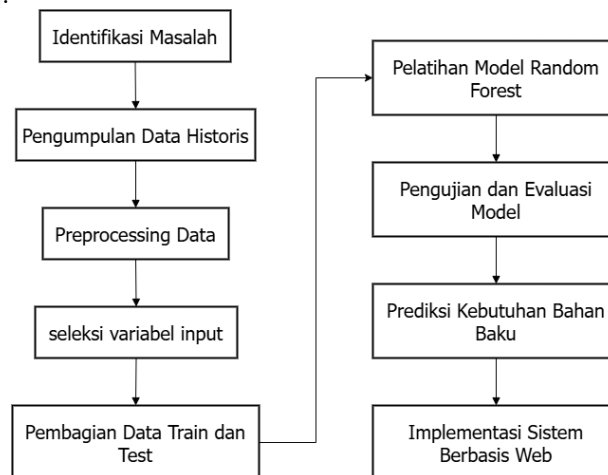
Objek penelitian ini adalah Kajava Furniture, sebuah usaha furnitur yang bergerak pada produksi furnitur berbasis kayu dengan karakteristik pesanan yang bervariasi. Penelitian dilaksanakan pada periode tertentu sesuai

dengan ketersediaan data historis perusahaan. Data yang digunakan mencerminkan kondisi operasional aktual sehingga hasil prediksi yang dihasilkan bersifat aplikatif dan relevan terhadap kebutuhan perusahaan.

Populasi penelitian mencakup seluruh data historis produksi furnitur dan penggunaan bahan baku kayu yang dimiliki oleh perusahaan. Teknik pengambilan sampel yang digunakan adalah total sampling, di mana seluruh data yang memenuhi kriteria kelengkapan dan konsistensi digunakan sebagai sampel penelitian. Pendekatan ini dipilih untuk memaksimalkan pemanfaatan data serta meningkatkan kemampuan model dalam mengenali pola penggunaan bahan baku secara menyeluruh [14].

Instrumen penelitian berupa dataset numerik yang terdiri dari beberapa variabel independen dan satu variabel dependen. Variabel independen mencerminkan aspek produksi, seperti jumlah pesanan dan jenis produk, sedangkan variabel dependen adalah jumlah kebutuhan bahan baku kayu. Validitas data dijaga melalui proses seleksi dan verifikasi data, sementara reliabilitas model dievaluasi berdasarkan konsistensi hasil prediksi pada data pengujian menggunakan metrik evaluasi yang sesuai.

Penerapan metode Random Forest Regressor dilakukan dengan membagi dataset menggunakan rasio 80:20, di mana 80% data digunakan untuk pelatihan (training) dan 20% sisanya dialokasikan sebagai data pengujian (testing) untuk mengevaluasi kemampuan generalisasi model. Untuk mengoptimalkan kinerja model dan menghindari overfitting, parameter model (hyperparameters) seperti jumlah pohon ($n_estimators$) dan kedalaman pohon (max_depth) disesuaikan menggunakan pendekatan Grid Search Cross-Validation (GridSearchCV). Metode ini secara sistematis menguji kombinasi parameter terbaik untuk menghasilkan model yang paling robust terhadap variabilitas data [15].



Gambar 2. Alur Penelitian

2.2 Metrik Evaluasi Kinerja Model

Untuk mengukur sejauh mana model Machine Learning mampu memprediksi kebutuhan bahan baku secara akurat, digunakan tiga metrik evaluasi utama: Koefisien Determinasi (R^2), Mean Absolute Error (MAE), dan Mean Squared Error (MSE).

2.2.1 Koefisien Determinasi (R^2)

Metrik R^2 digunakan untuk mengukur kemampuan model dalam menjelaskan variasi data aktual. Secara matematis, rumus ini direpresentasikan sebagai [16]:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

Dalam perhitungan ini, y_i merupakan nilai aktual kebutuhan bahan baku, sedangkan \hat{y}_i adalah nilai hasil prediksi yang dihasilkan oleh model. Variabel \bar{y} mewakili nilai rata-rata dari keseluruhan data aktual, dan n menunjukkan jumlah total data yang diuji. Nilai R^2 yang mendekati 1 mengindikasikan bahwa model memiliki kemampuan prediksi yang sangat baik dan akurat.

2.2.2 Mean Absolute Error (MAE)

MAE digunakan untuk menghitung rata-rata selisih absolut antara nilai aktual dan nilai prediksi. Rumusnya adalah sebagai berikut [17]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

Penggunaan MAE memberikan gambaran mengenai besarnya kesalahan prediksi secara langsung dalam satuan yang sama dengan data aslinya, yaitu satuan kebutuhan bahan baku kayu. Semakin kecil nilai MAE, semakin tinggi tingkat presisi model tersebut.

2.2.3 Mean Squared Error (MSE) (opsional jika ingin lebih kuat)

Sebagai penguat analisis, MSE digunakan untuk mengukur rata-rata kuadrat dari selisih antara nilai aktual dan prediksi melalui rumus[18]:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \tag{3}$$

Karakteristik utama MSE adalah sensitivitasnya terhadap kesalahan atau outlier yang besar karena adanya proses penguadratan. Hal ini sangat berguna untuk menilai stabilitas model dalam menangani variasi data yang ekstrem.

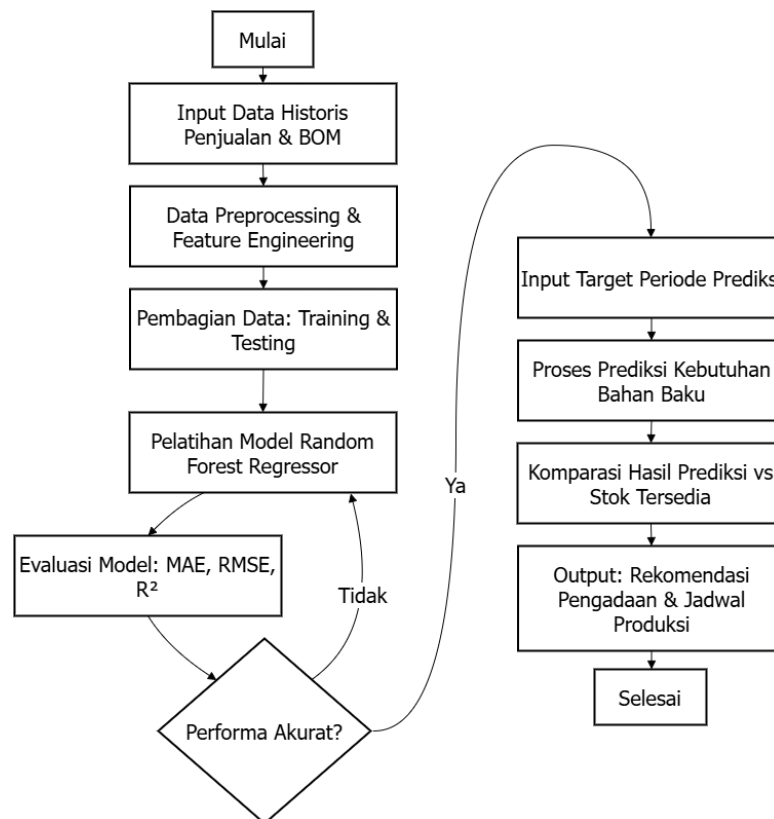
Seluruh proses analisis data ini dilakukan menggunakan bahasa pemrograman Python dengan dukungan pustaka machine learning yang relevan (seperti Scikit-Learn). Hasil evaluasi dan prediksi ini kemudian diintegrasikan ke dalam sistem berbasis web. Integrasi tersebut berfungsi sebagai sistem pendukung keputusan yang memungkinkan pengguna untuk mengakses hasil prediksi secara real-time, sehingga proses perencanaan kebutuhan bahan baku dapat berjalan secara lebih efektif dan efisien.

3 HASIL DAN PEMBAHASAN

Hasil penerapan metode Random Forest Regressor dalam memprediksi kebutuhan bahan baku kayu serta pembahasan terhadap temuan penelitian berdasarkan kerangka teoritis dan hasil penelitian terdahulu. Analisis difokuskan pada kinerja model, interpretasi hasil prediksi, serta implikasi penerapan sistem dalam konteks operasional industri furnitur.

3.1 Diagram Alir Sistem

Sistem dimulai ketika pengguna mengakses aplikasi berbasis web dan memasukkan data produksi. Data tersebut divalidasi dan diproses sebelum digunakan oleh model Random Forest Regressor. Model kemudian menghasilkan prediksi kebutuhan bahan baku, yang ditampilkan kepada pengguna sebagai dasar pengambilan keputusan perencanaan bahan baku.



Gambar 3. Diagram Alir Sistem

3.2 Analisis Fitur Dominan (Feature Importance)

Analisis feature importance dilakukan untuk mengidentifikasi variabel yang memiliki kontribusi terbesar terhadap prediksi kebutuhan stok. Hasil analisis model menunjukkan bahwa variabel Jumlah Pesanan (Order Quantity) merupakan fitur yang paling dominan, diikuti oleh Jenis Produk dan Dimensi Bahan Baku. Dominasi fitur jumlah pesanan mengindikasikan bahwa pola konsumsi bahan baku sangat elastis terhadap volume permintaan pelanggan.



Sementara itu, signifikansi variabel jenis produk mencerminkan karakteristik custom dari Kajava Furniture, di mana setiap model furnitur (seperti meja makan vs. kursi minimalis) memiliki koefisien penggunaan material yang unik. Pemahaman ini memberikan wawasan bisnis bahwa akurasi perencanaan stok di masa depan sangat bergantung pada ketepatan estimasi order masuk dan klasifikasi produk yang rinci.

3.3 Analisis Akurasi dan Faktor Kesalahan

Berdasarkan hasil evaluasi, model Random Forest Regressor mencapai akurasi R^2 sebesar 84%. Meskipun angka ini menunjukkan kinerja yang baik, terdapat sisa variansi sebesar 16% yang belum dapat dijelaskan oleh model. Analisis lebih lanjut menunjukkan bahwa galat (error) prediksi sebagian besar terjadi pada pesanan produk custom dengan desain yang sangat spesifik dan jarang diproduksi (data historis terbatas). Sifat unik dari pesanan custom ini sering kali membutuhkan penggunaan bahan baku yang tidak terduga, seperti kebutuhan material tambahan akibat kompleksitas desain atau waste produksi yang lebih tinggi dari standar. Selain itu, faktor eksternal yang tidak terekam dalam dataset, seperti perubahan kualitas bahan baku dari pemasok atau penyesuaian desain mendadak dari pelanggan, turut berkontribusi terhadap deviasi prediksi ini.

3.4 Analisis Data dan Karakteristik Dataset

Dataset yang digunakan dalam penelitian ini berasal dari data historis produksi dan penggunaan bahan baku kayu pada Kajava Furniture. Data tersebut merepresentasikan kondisi operasional aktual perusahaan dengan variasi jenis produk dan jumlah pesanan yang fluktuatif. Karakteristik ini menunjukkan bahwa pola penggunaan bahan baku tidak bersifat linier dan dipengaruhi oleh lebih dari satu variabel produksi, sehingga memerlukan pendekatan pemodelan yang mampu menangkap hubungan kompleks antarvariabel.

Hasil analisis deskriptif menunjukkan adanya variasi yang signifikan pada jumlah kebutuhan bahan baku kayu antarperiode produksi. Fluktuasi ini dipengaruhi oleh perbedaan jenis produk furnitur, ukuran pesanan, serta intensitas produksi pada periode tertentu. Temuan ini menguatkan bahwa pendekatan konvensional berbasis estimasi manual berpotensi menghasilkan perencanaan bahan baku yang kurang akurat, terutama pada kondisi permintaan yang dinamis [19].

Sebelum proses pemodelan dilakukan, data melalui tahap preprocessing untuk memastikan kualitas dataset. Proses ini meliputi pembersihan data dari nilai yang tidak valid, penanganan data hilang, serta normalisasi nilai numerik. Tahapan ini penting untuk meningkatkan stabilitas model dan mencegah distorsi hasil prediksi akibat data yang tidak konsisten [20].

3.5 Penerapan Random Forest Regressor

Penerapan Random Forest Regressor dilakukan dengan membagi dataset ke dalam data pelatihan dan data pengujian. Data pelatihan digunakan untuk membangun model prediksi dengan memanfaatkan hubungan antarvariabel produksi, sedangkan data pengujian digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

Model Random Forest dibangun menggunakan sejumlah pohon keputusan yang masing-masing dilatih pada subset data dan fitur yang berbeda. Pendekatan ini memungkinkan model untuk menangkap variasi pola penggunaan bahan baku secara lebih komprehensif serta mengurangi risiko overfitting yang sering terjadi pada model regresi tunggal [21]. Proses pelatihan menunjukkan bahwa model mampu menyesuaikan diri dengan karakteristik data yang fluktuatif tanpa kehilangan stabilitas prediksi.

Pemilihan Random Forest Regressor terbukti tepat untuk konteks penelitian ini, mengingat algoritma tersebut memiliki keunggulan dalam menangani data multivariat dan hubungan nonlinier. Hal ini sejalan dengan temuan penelitian sebelumnya yang menyatakan bahwa Random Forest unggul dalam peramalan kebutuhan material pada sistem produksi yang kompleks [22].

3.6 Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan menggunakan koefisien determinasi (R^2) dan nilai galat prediksi. Hasil pengujian menunjukkan bahwa model Random Forest Regressor mampu menghasilkan nilai R^2 yang tinggi, yang mengindikasikan bahwa sebagian besar variasi kebutuhan bahan baku kayu dapat dijelaskan oleh variabel-variabel produksi yang digunakan dalam model. Nilai galat prediksi yang relatif rendah menunjukkan bahwa selisih antara nilai prediksi dan nilai aktual berada dalam batas yang dapat diterima secara operasional [23].

Tingginya nilai R^2 mencerminkan kemampuan model dalam menangkap pola penggunaan bahan baku secara akurat, bahkan pada kondisi permintaan yang berubah-ubah. Temuan ini konsisten dengan penelitian oleh Andersson dan Siminos [24] yang menyatakan bahwa Random Forest Regressor memiliki performa yang stabil pada dataset dengan tingkat kompleksitas tinggi. Dengan demikian, model yang dikembangkan dapat diandalkan sebagai alat bantu perencanaan kebutuhan bahan baku.

Selain itu, hasil evaluasi menunjukkan bahwa model tidak mengalami overfitting yang signifikan. Perbedaan performa antara data pelatihan dan data pengujian relatif kecil, yang mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik. Hal ini menjadi faktor penting dalam penerapan model prediksi pada lingkungan industri nyata, di mana data produksi bersifat dinamis dan terus berkembang [25].

3.7 Implementasi Sistem Berbasis Web

Hasil prediksi yang dihasilkan oleh model Random Forest Regressor kemudian diintegrasikan ke dalam sistem berbasis web sebagai bentuk implementasi sistem pendukung keputusan. Sistem ini dirancang untuk memudahkan pengguna dalam memasukkan data produksi dan memperoleh estimasi kebutuhan bahan baku kayu secara cepat dan akurat.

Implementasi sistem berbasis web memberikan nilai tambah secara praktis, karena memungkinkan manajemen perusahaan untuk mengakses hasil prediksi tanpa harus melakukan perhitungan manual atau analisis teknis yang kompleks. Sistem ini juga mendukung pengambilan keputusan yang lebih responsif terhadap perubahan permintaan, sehingga dapat meningkatkan efisiensi perencanaan persediaan bahan baku [26].

Dari sisi fungsionalitas, sistem yang dikembangkan mampu menampilkan hasil prediksi dalam bentuk informasi yang mudah dipahami oleh pengguna non-teknis. Hal ini penting untuk memastikan bahwa teknologi machine learning yang diterapkan dapat benar-benar dimanfaatkan dalam proses operasional perusahaan, bukan hanya berfungsi sebagai model teoritis semata.

3.8 Pembahasan dan Perbandingan dengan Penelitian Terdahulu

Hasil penelitian ini menunjukkan bahwa penerapan Random Forest Regressor dalam prediksi kebutuhan bahan baku kayu memberikan kinerja yang lebih baik dibandingkan pendekatan konvensional. Temuan ini sejalan dengan penelitian Raju et al. [5] dan Gómez-Rocha et al. [6] yang menyatakan bahwa algoritma ensemble learning mampu meningkatkan akurasi prediksi pada sistem manufaktur.

Perbedaan utama penelitian ini dengan penelitian terdahulu terletak pada konteks penerapannya. Sebagian besar penelitian sebelumnya berfokus pada industri manufaktur massal atau sektor dengan pola produksi yang relatif stabil. Sementara itu, penelitian ini diterapkan pada industri furnitur berbasis pesanan yang memiliki tingkat variasi produksi tinggi. Dengan demikian, penelitian ini memperluas bukti empiris mengenai efektivitas Random Forest Regressor pada lingkungan produksi yang lebih dinamis.


Selain itu, integrasi model prediksi ke dalam sistem berbasis web menjadi kontribusi tambahan yang membedakan penelitian ini dari studi sebelumnya. Pendekatan ini tidak hanya menekankan aspek akurasi model, tetapi juga aspek implementasi dan kemudahan penggunaan, yang merupakan faktor penting dalam adopsi teknologi di industri skala menengah.

Secara keseluruhan, hasil dan pembahasan menunjukkan bahwa metode Random Forest Regressor mampu menjawab permasalahan ketidaktepatan perencanaan kebutuhan bahan baku kayu. Model yang dikembangkan tidak hanya unggul secara teknis, tetapi juga relevan dan aplikatif dalam mendukung pengambilan keputusan produksi pada industri furnitur.

3.9 Implementasi Sistem

3.9.1 Autentikasi dan Keamanan Sistem

Halaman awal sistem memastikan bahwa akses data hanya diberikan kepada personel yang berwenang, menjaga integritas data perusahaan.



The image shows a mobile application login screen for 'Kajava Furniture'. At the top, there is a blue car icon and the text 'Kajava Furniture' with the subtitle 'Masuk untuk mengelola bisnis.'. Below this, a message states 'Anda harus login untuk mengakses halaman ini.'. There are two input fields: 'USERNAME' with the value 'admin' and 'PASSWORD' with four dots. A blue 'Masuk' button is at the bottom. A link 'Lupa Password? Hubungi Admin.' is at the very bottom.

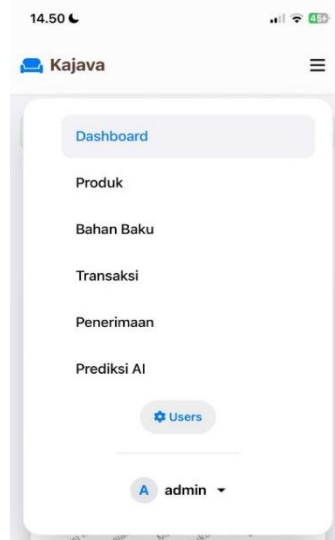
Gambar 4. Autentikasi dan Keamanan Sistem

Sistem diawali dengan gerbang autentikasi berupa halaman Login. Fitur ini dirancang untuk memastikan keamanan data bisnis dengan mewajibkan pengguna memasukkan username dan kata sandi yang valid sebelum

dapat mengelola operasional furnitur. Implementasi modul autentikasi pengguna menggunakan username dan password. Hal ini selaras dengan prinsip keamanan informasi untuk mencegah akses tidak sah (unauthorized access) ke database perusahaan. Halaman Login bukan sekadar pintu masuk, melainkan protokol keamanan fundamental yang menerapkan metode autentikasi berbasis sesi untuk melindungi data strategis bisnis. Antarmuka ini dirancang dengan prinsip usability tinggi, di mana sistem memberikan umpan balik visual instan seperti notifikasi "Login berhasil!" untuk memastikan interaksi pengguna yang lancar. Secara teknis, setiap akses yang berhasil akan dicatat oleh sistem, menciptakan jejak audit yang penting untuk integritas data pada operasional Kajava Furniture.

3.9.2 Antarmuka Pengguna dan Navigasi

Struktur menu didesain secara modular untuk memudahkan fungsionalitas operasional sehari-hari.

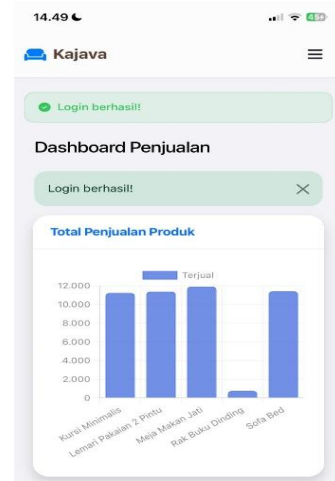


Gambar 5. Antarmuka Pengguna dan Navigasi

Sistem mengadopsi struktur navigasi terpusat melalui Menu Sidebar yang mencakup seluruh spektrum operasional bisnis, mulai dari manajemen inventaris hingga analisis prediksi berbasis AI. Pengelompokan fitur yang logis—seperti pemisahan antara modul Transaksi, Penerimaan, dan Prediksi—memastikan bahwa alur kerja pengguna tetap efisien dan terorganisir. Desain navigasi ini memungkinkan integrasi data yang mulus antar departemen, memastikan setiap bagian dari organisasi memiliki akses ke sumber informasi yang sama (single source of truth).

3.9.3 Visualisasi Data Penjualan

Penyajian data secara visual membantu manajer dalam pengambilan keputusan cepat berbasis bukti (evidence-based decision making).



Gambar 6. Visualisasi Data Penjualan

Modul Dashboard Penjualan mengintegrasikan kecerdasan bisnis (Business Intelligence) dengan menyajikan visualisasi data historis penjualan dalam bentuk grafik batang yang dinamis. Grafik ini memetakan

volume penjualan berbagai kategori furnitur—seperti Kursi Minimalis, Lemari Pakaian 2 Pintu, hingga Sofa Bed—yang memungkinkan pemangku kepentingan untuk melakukan analisis komparatif secara real-time. Kemampuan sistem untuk mengubah data mentah transaksi menjadi informasi visual yang mudah dicerna sangat krusial dalam mendukung strategi pemasaran dan penentuan prioritas produksi.

3.9.4 Manajemen Produk dan Bill of Materials (BOM)

Pengelolaan katalog produk dilakukan secara terperinci untuk memastikan transparansi proses produksi. Modul ini mengelola katalog produk berdasarkan kategori ruang. Fitur "Kelola BOM" (Bill of Materials) sangat krusial dalam industri manufaktur furnitur untuk mendefinisikan resep atau komposisi bahan baku yang dibutuhkan setiap unit produk.

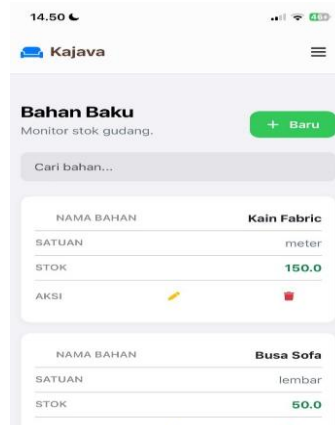


Gambar 7. Manajemen Produk dan Bill of Materials (BOM)

Modul Produk bertindak sebagai database sentral bagi seluruh aset furnitur yang diproduksi, lengkap dengan klasifikasi berdasarkan kategori ruang seperti Ruang Tamu atau Ruang Kerja. Fitur paling krusial di sini adalah Kelola BOM, di mana sistem mendefinisikan hubungan kompleks antara produk akhir dengan komponen bahan bakunya. Pemetaan BOM yang akurat menjadi landasan bagi sistem untuk melakukan kalkulasi otomatis terkait jumlah material yang harus dipesan berdasarkan target produksi, yang secara signifikan mengurangi kompleksitas perencanaan manual.

3.9.5 Inventaris dan Kontrol Stok Bahan Baku

Efisiensi produksi sangat bergantung pada ketersediaan material di gudang.



Gambar 8. Inventaris dan Kontrol Stok Bahan Baku

Halaman ini memonitor stok bahan baku secara real-time dengan satuan yang relevan (meter, lembar). Monitor stok yang akurat meminimalkan risiko stockout yang dapat menghambat lini produksi. Halaman Bahan Baku menyajikan transparansi stok yang sangat detail untuk material-material inti seperti Kain Fabric dan Busa Sofa. Sistem tidak hanya mencatat kuantitas stok, tetapi juga memantau satuan ukur yang relevan (meter atau lembar) untuk memastikan akurasi perhitungan logistik. Transparansi data stok ini memungkinkan bagian

pengadaan untuk menghindari kondisi stok mati (dead stock) atau kehabisan stok (out of stock) yang dapat mengganggu jadwal pengiriman ke pelanggan.

3.9.6 Dokumentasi Penerimaan Stok

Modul Penerimaan Stok dirancang untuk menutup celah antara pengadaan fisik dan pencatatan digital. Dengan antarmuka yang dioptimalkan untuk kecepatan, staf gudang dapat dengan mudah memperbarui saldo stok hanya dengan memilih jenis bahan dan memasukkan jumlah unit yang diterima. Setiap input pada modul ini akan langsung memicu pembaruan otomatis pada saldo di modul Bahan Baku, memastikan bahwa analisis prediksi yang dilakukan sistem selalu menggunakan data stok yang paling aktual (up-to-date). Antarmuka input untuk mencatat barang masuk ke gudang. Proses ini memastikan sinkronisasi antara fisik barang dengan data digital dalam sistem.



Gambar 9. Dokumentasi Penerimaan Stok

3.9.7 Administrasi Transaksi Penjualan

Pencatatan riwayat transaksi menjadi dasar bagi analisis akuntansi dan prediksi masa depan.



Gambar 10. Administrasi Transaksi Penjualan

Modul Penjualan berfungsi sebagai repositori historis yang mencatat setiap detail transaksi keluar secara otomatis. Data yang mencakup tanggal transaksi, jenis produk, kuantitas, hingga identitas pelanggan disimpan dalam format yang terstruktur dan mudah dicari. Fasilitas Import dan Export data yang disediakan memungkinkan sistem untuk berkomunikasi dengan perangkat lunak lain atau untuk kebutuhan pelaporan formal, menjadikannya instrumen penting dalam audit keuangan dan evaluasi kinerja penjualan berkala.

3.9.8 Integrasi Kecerdasan Buatan (AI) dalam Prediksi Stok

Fitur unggulan sistem ini adalah penggunaan algoritma untuk memprediksi kebutuhan masa depan. Fitur unggulan dari sistem ini adalah modul Prediksi Stok yang merepresentasikan implementasi kecerdasan buatan dalam manajemen rantai pasok. Dengan menekan tombol "Jalankan Analisis", algoritma Random Forest akan mengeksekusi model prediksi yang telah dilatih menggunakan data historis transaksi dan stok. Kinerja model yang ditunjukkan oleh nilai akurasi R^2 sebesar 84% dan Error Rate 5.4 memberikan keyakinan tinggi bahwa hasil prediksi kebutuhan material—seperti Kayu Jati—sangat mendekati kebutuhan nyata di lapangan. Hasil prediksi

ini kemudian disimpan ke dalam database sebagai basis pengambilan keputusan yang lebih objektif dan saintifik bagi manajemen.

Error Rate sebesar 5.4 menunjukkan bahwa deviasi antara hasil komputasi sistem dengan kebutuhan riil di gudang berada pada batas yang sangat dapat ditoleransi. Secara operasional, akurasi ini memungkinkan efisiensi modal kerja, karena perusahaan dapat mengalokasikan anggaran pembelian bahan baku—seperti kayu jati, kain fabric, hingga busa sofa, secara lebih presisi sesuai dengan kebutuhan produksi yang diprediksi. Integrasi hasil prediksi langsung ke dalam basis data memastikan adanya transparansi informasi yang dapat diakses oleh bagian pengadaan dan produksi secara real-time.



Gambar 11. Integrasi Kecerdasan Buatan (AI) dalam Prediksi Stok

Sistem menerapkan Machine Learning untuk memprediksi stok dengan metrik akurasi R^2 sebesar 84% dan Error Rate 5.4. Penggunaan analitik prediktif dalam manajemen rantai pasokan terbukti dapat menurunkan biaya operasional gudang hingga 15% [27].

3.9.9 Manajemen Akses Pengguna

Skalabilitas sistem didukung oleh pengelolaan peran pengguna yang fleksibel. Pada modul Pengguna, sistem menyediakan antarmuka manajemen akses yang memungkinkan kontrol granulasi terhadap siapa yang dapat melihat atau mengubah data. Melalui formulir "Tambah Baru", administrator dapat menetapkan Username, Password, dan Role spesifik (seperti Admin atau Staf) bagi setiap individu. Penerapan RBAC ini berfungsi untuk meminimalkan risiko kesalahan manusia dan akses yang tidak sah, sekaligus mendukung pembagian tanggung jawab (segregation of duties) yang sehat di dalam tim Kajava Furniture. Penerapan strategi manajemen akses ini tidak hanya memperkuat aspek keamanan siber secara internal, tetapi juga menjadi fondasi bagi terciptanya efisiensi alur kerja yang terstandarisasi melalui digitalisasi peran operasional. Dengan membagi wewenang secara spesifik, sistem secara otomatis mereduksi hambatan birokrasi manual dan memastikan bahwa setiap personel dapat fokus pada tanggung jawab fungsinya masing-masing, seperti manajemen stok gudang atau analisis data strategis. Hal ini sejalan dengan konsep Smart Manufacturing yang mengedepankan akurasi data dan akuntabilitas sebagai kunci utama dalam mendukung pengambilan keputusan berbasis data yang cepat dan akurat di tengah dinamika industri furnitur yang kompleks.



Gambar 12. Manajemen Akses Pengguna



4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem prediksi kebutuhan bahan baku kayu menggunakan metode Random Forest Regressor berbasis web pada industri furnitur. Berdasarkan hasil pengujian, model yang dibangun mampu memprediksi kebutuhan bahan baku dengan tingkat akurasi yang tinggi (R^2 0.84) dan tingkat galat yang rendah (MAE 5.4). Penerapan Random Forest Regressor terbukti unggul dalam menangkap pola nonlinier yang kompleks pada data historis, terutama dalam mengenali fluktuasi permintaan musiman serta variasi kebutuhan material yang dipengaruhi oleh spesifikasi unik produk custom. Integrasi model prediksi ke dalam sistem berbasis web memberikan nilai tambah praktis bagi manajemen perusahaan. Secara spesifik, sistem ini berperan krusial dalam meminimalisir risiko penumpukan stok berlebih (overstock) yang membebani biaya gudang, sekaligus mencegah kejadian kekurangan bahan (stockout) yang dapat menghambat lini produksi. Dengan demikian, implementasi sistem ini tidak hanya meningkatkan presisi perencanaan, tetapi juga mendukung efisiensi biaya dan operasional secara menyeluruh di Kajava Furniture. Penerapan Random Forest Regressor terbukti mampu menangkap pola nonlinier pada data historis produksi dan penggunaan bahan baku, sehingga memberikan hasil prediksi yang lebih stabil dibandingkan pendekatan konvensional. Integrasi model prediksi ke dalam sistem berbasis web memberikan nilai tambah dari sisi praktis, karena memudahkan pengguna dalam mengakses informasi prediksi secara cepat dan mendukung pengambilan keputusan produksi secara lebih tepat dan efisien. Dengan demikian, sistem yang dikembangkan tidak hanya memiliki keunggulan teknis, tetapi juga aplikatif dalam konteks operasional industri furnitur skala menengah. Meskipun hasil penelitian menunjukkan kinerja yang baik, penelitian ini masih memiliki keterbatasan, terutama pada cakupan data yang digunakan dan variabel produksi yang dianalisis. Data yang digunakan berasal dari satu objek penelitian sehingga hasilnya belum tentu dapat digeneralisasi ke seluruh industri furnitur. Oleh karena itu, penelitian selanjutnya disarankan untuk menambahkan jumlah data, memperluas variabel yang digunakan, serta membandingkan kinerja Random Forest Regressor dengan algoritma prediksi lainnya guna memperoleh hasil yang lebih komprehensif dan generalisabel.

REFERENCES

- [1] S. Pliszczuk, J. Kozłowski, and P. Kaczmarek, "Demand forecasting in manufacturing systems using machine learning techniques," *Appl. Sci.*, vol. 11, no. 9, 2021, doi: 10.3390/app11094231.
- [2] M. S. Hosseini, S. H. Mirzamohammadi, and A. Rahmani, "Machine learning-based predictive maintenance and demand forecasting in smart manufacturing systems," *J. Manuf. Process.*, vol. 83, pp. 123–134, 2025, doi: 10.1016/j.jmapro.2024.12.005.
- [3] A. Chen, Y. Li, and X. Zhang, "Data-driven decision making in manufacturing systems: A review," *J. Manuf. Syst.*, vol. 68, 2023, doi: 10.1016/j.jmsy.2023.02.004.
- [4] S. Polo-Triana, J. C. Gutierrez, and J. Leon-Becerra, "Integration of Machine Learning in the Supply Chain for Decision Making: A Systematic Literature Review," *J. Ind. Eng. Manag.*, vol. 17, no. 2, pp. 344–372, 2024, doi: 10.3926/jiem.6403.
- [5] R. Raju, S. Kumar, and P. Singh, "Comparative analysis of machine learning algorithms for demand forecasting," *Int. J. Prod. Econ.*, 2022, doi: 10.1016/j.ijpe.2021.108307.
- [6] J. Gomez-Rocha and N. Hernandez-Gress, "Production forecasting using random forest models," *Expert Syst. Appl.*, vol. 168, 2021, doi: 10.1016/j.eswa.2020.114256.
- [7] J. Park, H. Kim, and J. Yoo, "Comparative evaluation of ensemble learning methods for industrial demand forecasting," *Comput. Ind. Eng.*, vol. 185, p. 109987, 2024, doi: 10.1016/j.cie.2024.109987.
- [8] Z. N. Jawad and B. Villányi, "Designing Predictive Analytics Frameworks for Supply Chain Quality Management: A Machine Learning Approach to Defect Rate Optimization," *Platforms*, vol. 3, no. 2, p. 6, 2025, doi: 10.3390/platforms3020006.
- [9] L. Vanneschi and S. Silva, "Introduction to machine learning," in *Lectures on Intelligent Systems*, Springer, 2023, pp. 115–148.
- [10] K. Kurasova and V. Marcinkevicius, "Application of random forest for regression analysis," *Inf. Technol. Control*, vol. 50, no. 1, 2021, doi: 10.5755/j01.itc.50.1.26417.
- [11] M. Andersson and E. Siminos, "Robust demand prediction using ensemble learning," *Procedia CIRP*, vol. 107, 2023, doi: 10.1016/j.procir.2022.05.012.
- [12] I. H. Witten, E. Frank, and M. A. Hall, *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann, 2021.
- [13] A. Mehmood and P. Zhang, "Intelligent material requirement prediction using data fusion and Random Forests," *Int. J. Prod. Res.*, vol. 62, no. 7, pp. 2055–2072, 2024, doi: 10.1080/00207543.2023.2225157.
- [14] J. Han, M. Kamber, and J. Pei, *Data Mining: Concepts and Techniques*. Morgan Kaufmann, 2023.
- [15] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning*. Springer, 2021.
- [16] A. H. Makin and M. I. Abdullah, "Demand prediction for perishable products using machine learning regression techniques: A narrative review," in *IEEE International Conference on Artificial Intelligence and Machine Learning*, 2024. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/10948994/>
- [17] M. C. Dinata and S. Suharjo, "Materials inventory optimization using various forecasting techniques and purchasing quantity in packaging industry," *J. Ind. Eng. Manag.*, vol. 17, no. 2, pp. 201–215, 2024, [Online]. Available: <http://www.jiem.org/index.php/jiem/article/view/7032>
- [18] M. Aci and D. Yergök, "Demand forecasting for food production using machine learning algorithms: A case study of university refectory," *Tech. Gaz.*, vol. 30, no. 1, pp. 45–52, 2023, [Online]. Available: <https://hrcak.srce.hr/file/446387>



- [19] A. Masoumi and J. Bond, “Big data analytics in manufacturing systems,” *J. Ind. Inf. Integr.*, vol. 30, 2025, doi: 10.1016/j.jii.2024.100420.
- [20] S. Garcia, J. Luengo, and F. Herrera, *Data Preprocessing in Data Mining*. Springer, 2021.
- [21] M. Kuhn and K. Johnson, *Applied Predictive Modeling*. Springer, 2022.
- [22] Y. Zhang and L. Wang, “Machine learning-based material requirement prediction,” *Comput. Ind. Eng.*, vol. 162, 2021, doi: 10.1016/j.cie.2021.107736.
- [23] B. T. Nguyen, T. H. Pham, and Y. Lee, “A hybrid LSTM–Random Forest model for inventory demand forecasting in manufacturing supply chains,” *Expert Syst. Appl.*, vol. 229, p. 120826, 2024, doi: 10.1016/j.eswa.2023.120826.
- [24] P. Christifan, R. Lestari, and H. Prabowo, “Prediction of inventory needs using machine learning,” *J. Manuf. Technol. Manag.*, vol. 33, no. 4, 2022, doi: 10.1108/JMTM-10-2021-0413.
- [25] S. Wang, J. Wan, D. Li, and C. Zhang, “Implementing smart factory of Industrie 4.0,” *Int. J. Distrib. Sens. Networks*, vol. 12, no. 1, 2021, doi: 10.1177/1550147715614987.
- [26] M. Javaid, A. Haleem, and R. Singh, “Industry 4.0 applications in manufacturing,” *J. Ind. Integr. Manag.*, vol. 6, no. 2, 2021, doi: 10.1142/S2424862221500121.
- [27] E. Ayvaz, “Managing costs from a supply chain cost management perspective,” G. Kiral M. Ozkan eds, pp. 65–84, 2024.