

Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi
 Jl. Ahmad Yani, K.M. 33,5 - Kampus STMIK Banjarbaru
 Loktabat – Banjarbaru (Tlp. 0511 4782881), e-mail: puslit.stmikbjb@gmail.com
 e-ISSN: 2685-0893
 p-ISSN: 2089-3787

Implementasi *Decision Tree* untuk Prediksi Kebutuhan Bahan Kain Pada Usaha Konveksi

Dwi Septiani^{1*}, Evanita², Arief Susanto³

Teknik Informatika, Universitas Muria Kudus, Kudus, Indonesia

*e-mail *Corresponding Author*: 202151110@std.umk.ac.id

Abstract

Convection businesses often inaccurately estimate fabric demand, leading to stock waste or material shortages that disrupt production. This study aimed to improve fabric demand prediction accuracy at Threetan Collection by applying the Decision Tree Regressor algorithm. The model was developed using historical production data consisting of five key variables: pants size, fabric type, fabric brand, pants model, and order quantity. The dataset was divided into 80% training and 20% testing. Two model versions were developed: one without parameter optimization and another with hyperparameter optimization using RandomizedSearchCV. The optimized model demonstrated better performance, achieving a mean absolute error of 0.7851 yards and explaining 98.62% of data variability. The results show that the proposed model enhances fabric stock management efficiency. The model has been implemented in a web-based application using Flask and MySQL to support a more effective production process.

Keywords: *Decision Tree Regressor; Fabric demand prediction; Hyperparameter optimization; RandomizedSearchCV; Flask*

Abstrak

Usaha konveksi sering mengalami kesalahan dalam estimasi kebutuhan bahan kain, yang menyebabkan pemborosan stok atau kekurangan bahan yang menghambat produksi. Penelitian ini bertujuan untuk meningkatkan akurasi prediksi kebutuhan kain pada usaha konveksi Threetan Collection dengan menerapkan algoritma *Decision Tree Regressor*. Model dikembangkan berdasarkan data historis produksi yang terdiri dari lima variabel utama: ukuran celana, jenis kain, merek kain, model celana, dan jumlah pesanan. Dataset dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Dua versi model dikembangkan, yaitu tanpa optimasi parameter dan dengan optimasi hyperparameter menggunakan *RandomizedSearchCV*. Model yang dioptimasi menunjukkan performa lebih baik, dengan kesalahan absolut rata-rata sebesar 0,7851 yard dan mampu menjelaskan 98,62% variabilitas data. Hasil penelitian menunjukkan bahwa model yang diusulkan dapat meningkatkan efisiensi manajemen stok bahan kain. Model ini telah diimplementasikan dalam aplikasi berbasis web menggunakan *Flask* dan *MySQL* untuk mendukung proses produksi secara lebih efektif.

Kata kunci: *Decision Tree Regressor; Prediksi kebutuhan kain; Optimasi hyperparameter; RandomizedSearchCV; Flask*

1. Pendahuluan

Sektor konveksi menempati posisi yang signifikan dalam kerangka ekonomi, terutama dalam mengatasi kebutuhan sandang dan penciptaan lapangan kerja [1]. Sebagai bagian dari industri tekstil, sektor ini memberikan kontribusi signifikan dalam meningkatkan kesejahteraan masyarakat serta mendukung pertumbuhan usaha kecil, mikro, dan menengah (UMKM). Namun, tantangan utama yang dihadapi oleh UMKM di sektor ini adalah pengelolaan bahan baku, khususnya kain [2]. Pengelolaan yang tidak optimal dapat menyebabkan kelebihan atau kekurangan stok bahan, yang berdampak pada efisiensi produksi dan biaya operasional [2]. Masalah ini menjadi semakin kompleks ketika variasi ukuran dan jenis bahan kain mempengaruhi kebutuhan produksi secara keseluruhan [2].

Threetan Collection adalah UMKM yang bergerak di bidang konveksi celana kolor. Saat ini, mereka masih menggunakan metode manual dalam menentukan kebutuhan bahan kain. Proses ini sering kali menyebabkan kelebihan stok yang meningkatkan biaya penyimpanan

atau kekurangan bahan yang dapat menghambat produksi dan pengiriman pesanan. Selain itu, jumlah celana yang dapat dihasilkan dari satu gulungan kain bervariasi tergantung pada ukuran dan jenis kain, sehingga perhitungan kebutuhan bahan sering kali kurang akurat. Ketidakakuratan dalam pengelolaan bahan baku ini berdampak pada efisiensi produksi, meningkatkan risiko pemborosan, serta menurunkan daya saing usaha di pasar yang kompetitif. Oleh karena itu, diperlukan suatu sistem yang dapat membantu memprediksi kebutuhan bahan kain secara lebih akurat untuk meningkatkan efisiensi operasional.

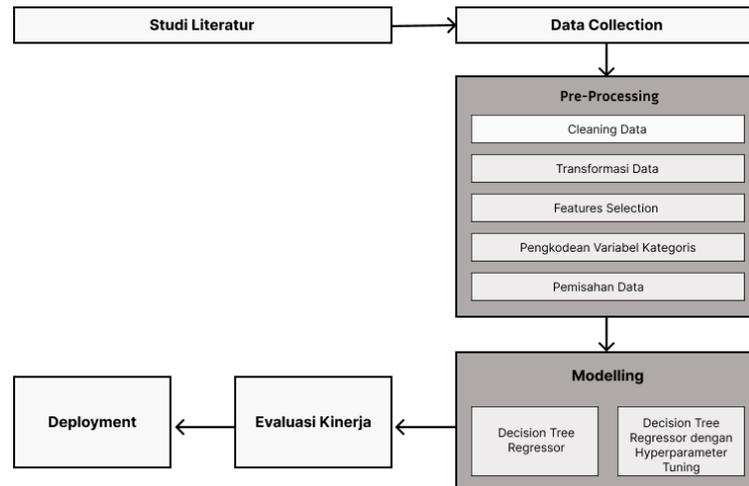
Beberapa penelitian sebelumnya telah berusaha menyelesaikan permasalahan prediksi kebutuhan pakaian dengan menerapkan metode *machine learning* untuk mendukung pengambilan keputusan dalam industri tekstil [3]. Penelitian yang dilakukan oleh J. Prakash [4] mengevaluasi model *machine learning* seperti *Regresi Logistik*, *K-Nearest Neighbors (KNN)*, *Random Forest*, dan *Decision Tree* untuk meningkatkan akurasi prediksi ukuran pakaian dalam industri *e-commerce*. Di antara berbagai metode *machine learning* yang digunakan dalam penelitian tersebut, *Decision Tree* memiliki hasil akurasi terbaik yaitu 0,99 untuk prediksi ukuran baju dan 0,89 untuk prediksi ukuran celana. Studi ini menunjukkan bahwa penerapan *machine learning* dapat mengoptimalkan proses produksi dan distribusi pakaian, tetapi tidak membahas integrasi model ini ke dalam platform *e-commerce* yang ada atau tantangan praktis yang mungkin timbul selama implementasi, seperti desain antarmuka pengguna dan masalah privasi data pelanggan [4]. Selain itu, penelitian tersebut tidak mempertimbangkan faktor jenis kain, variasi ukuran merek, dan bentuk tubuh pelanggan, serta belum fokus pada pengelolaan bahan baku di UMKM konveksi [4]. Studi lain yang dilakukan oleh Amin Fahri [5] menunjukkan bahwa *Decision Tree* memiliki akurasi tinggi dalam berbagai bidang prediksi, termasuk pemodelan hasil COVID-19 dengan nilai R^2 sebesar 0,956. Penelitian lain juga membuktikan keunggulan *Decision Tree Regression* dibandingkan *Linear Regression* dalam prediksi harga saham *Apple* [6]. Keunggulan *Decision Tree* dalam menangani data kompleks dan menghasilkan prediksi akurat menjadikannya metode yang sesuai untuk diterapkan dalam prediksi kebutuhan bahan kain pada UMKM konveksi.

Untuk mengatasi permasalahan dalam pengelolaan bahan kain pada UMKM konveksi, penelitian ini mengusulkan penerapan metode *decision tree regressor* untuk memprediksi kebutuhan bahan kain secara lebih akurat. *Decision Tree* dipilih karena kemampuannya dalam menangani data kompleks serta memberikan prediksi yang lebih tepat dibandingkan metode lainnya [4][5][6][7]. Penelitian ini berbeda dari studi sebelumnya yang berfokus pada prediksi ukuran pakaian dalam *e-commerce* [4] serta penerapan *decision tree* dalam berbagai bidang, seperti prediksi hasil COVID-19 [5] dan perkiraan harga saham [6]. Model-model sebelumnya tidak mempertimbangkan faktor spesifik industri konveksi, terutama dalam aspek pengelolaan bahan baku. Oleh karena itu, penelitian ini mengembangkan model prediksi yang lebih sesuai dengan kebutuhan industri konveksi, khususnya pada usaha Threetan Collection. Model ini akan menganalisis data historis yang mencakup variasi ukuran celana, jenis bahan kain, model celana, jumlah pesanan, serta jumlah kain yang digunakan dalam produksi massal (dalam yard). Implementasi model ini diharapkan dapat meningkatkan akurasi prediksi, mengurangi risiko pemborosan bahan, dan mencegah kekurangan stok yang dapat menghambat produksi. Sebagai langkah akhir, model *decision tree* akan dideploy dalam bentuk prototipe aplikasi berbasis website menggunakan *framework Flask*. Pengembangan aplikasi ini bertujuan untuk membantu optimalisasi proses produksi di Threetan Collection serta meningkatkan efisiensi pengelolaan bahan baku.

Dengan adanya penelitian ini, diharapkan kontribusi terhadap sektor konveksi dalam mengadopsi teknologi berbasis *machine learning* dapat semakin meningkat. Kebaruan dari penelitian ini terletak pada penerapan algoritma *Decision Tree* dalam sistem prediksi kebutuhan bahan kain pada UMKM konveksi, yang sebelumnya belum banyak diteliti. Model yang dihasilkan diharapkan dapat menjadi referensi bagi UMKM lain dalam mengelola bahan baku secara lebih efisien.

2. Metode Penelitian

Metode penelitian yang digunakan untuk mengimplementasikan algoritma *Decision Tree* dalam prediksi kebutuhan bahan kain pada usaha konveksi Threetan Collection dapat dipecah menjadi beberapa tahap, yaitu *Data Collection*, *Pre-Processing*, Pengembangan *Modelling*, Evaluasi Kinerja, dan *Deployment*, seperti yang ditunjukkan pada Gambar 1.



Gambar 1 Tahap Metode Penelitian

2.1. Studi Literatur

Studi literatur dalam penelitian ini bertujuan untuk memahami konsep-konsep yang relevan dengan prediksi kebutuhan bahan kain untuk usaha konveksi celana. Kajian ini mencakup eksplorasi teori machine learning, teknik regresi, pengolahan data, serta metode evaluasi kinerja model. Studi juga meninjau aplikasi Decision Tree sebagai algoritma yang digunakan, termasuk penerapan hyperparameter tuning dan metode evaluasinya. Literatur yang dirujuk mencakup jurnal, buku, serta artikel terkait untuk memberikan dasar teori yang kuat dan mendukung pengembangan penelitian.

2.2. Data Collection

Pada tahap ini, data historis terkait produksi celana kolor dikumpulkan dari Threetan Collection. Data yang dikumpulkan mencakup 11 fitur/variabel yang meliputi ukuran celana (mini, kecil, tanggung, standart, jumbo), panjang depan celana, lebar depan, panjang belakang, lebar belakang, jenis kain/merk kain, warna, model celana, jumlah pesanan/hasil produksi, luas kain, dan jumlah kain (yard). Proses pengumpulan data dilakukan melalui berbagai metode, termasuk pengambilan data dari catatan produksi, wawancara dengan pemilik dan karyawan untuk memperoleh informasi tambahan terkait faktor-faktor yang memengaruhi kebutuhan bahan kain, serta observasi langsung pada proses produksi untuk memahami pola penggunaan bahan kain berdasarkan jenis dan ukuran celana. Periode pengumpulan data diperoleh dalam rentang bulan Juni hingga Desember 2024 dengan total 386 record data. Setelah data terkumpul, dilakukan proses verifikasi untuk memastikan konsistensi dan akurasi sebelum melanjutkan ke tahap *pre-processing*.

2.3. Pre-Processing

Pre-processing data merupakan fase penting dalam bidang analisis data dan pembelajaran mesin yang melibatkan persiapan data mentah untuk analisis atau pemodelan lebih lanjut untuk meningkatkan kualitas data [5],[8]. Langkah-langkah dalam tahap *pre-processing* pada penelitian ini meliputi:

- 1) *Cleaning Data*: Proses ini melibatkan identifikasi dan perbaikan kesalahan atau inkonsistensi dalam data yang terkumpul, seperti menghapus data duplikat, mengisi nilai kosong, dan memperbaiki ketidakakuratan agar data lebih valid [5]. Dalam penelitian ini, pembersihan data dilakukan hanya dengan menghapus baris yang kosong.
- 2) *Transformasi Data*: Untuk memastikan bahwa data direpresentasikan dalam skala yang konsisten, proses normalisasi atau standardisasi dapat diterapkan. Prosedur ini sangat penting untuk model regresi karena dapat membuat model lebih akurat dan mempercepat proses pembelajaran [7]. Dalam penelitian ini standardisasi menggunakan metode *Standard Scaler*.
- 3) *Features Selection*: Preprocessing data sering mencakup pemilihan fitur yang paling relevan untuk meningkatkan kinerja model dan mengurangi *overfitting* dengan

menghapus data yang tidak penting [9]. Awalnya, dataset produksi celana Threetan Collection memiliki 11 fitur. Setelah proses seleksi fitur, hanya 5 fitur yang dipertahankan: ukuran celana, jenis kain/merk kain, model celana, jumlah pesanan/hasil produksi, dan jumlah kain (yard). Fitur jumlah kain (yard) digunakan sebagai variabel target.

- 4) Pengkodean Variabel Kategoris: Banyak algoritma pembelajaran mesin membutuhkan input numerik [8]. Proses *preprocessing* mencakup transformasi variabel kategoris menjadi representasi numerik, dalam penelitian ini, digunakan teknik pengkodean label.
- 5) Pemisahan Data: Dataset umumnya dibagi menjadi dua bagian: set pelatihan dan set pengujian [8]. Set pelatihan digunakan untuk tujuan pelatihan model, sedangkan set pengujian berfungsi untuk menilai kinerja model pada data yang belum pernah ditemui sebelumnya [10]. Dalam penelitian ini, alokasi dataset ditetapkan pada 80% yang ditujukan untuk pelatihan dan 20% untuk pengujian.
- 6)

2.4. Modelling

Modelling atau pemodelan merupakan komponen penting dari machine learning, yang mencakup proses pemilihan algoritma, pelatihan model, dan penilaian kinerja untuk memecahkan masalah tertentu secara efektif [8],[11]. Untuk mencapai tujuan penelitian, yaitu prediksi kebutuhan bahan kain untuk usaha konveksi celana Threetan Collection, algoritma pembelajaran mesin digunakan. Algoritma yang digunakan dalam eksperimen ini adalah *Decision Tree*.

Decision tree adalah teknik kecerdasan buatan yang menggambarkan pilihan dan alternatif di setiap cabang, dengan daun yang menunjukkan opsi yang dipilih [12]. Model ini digunakan untuk klasifikasi dan regresi dengan membagi data menjadi subset berdasarkan nilai fitur input, membentuk struktur pohon yang mudah dipahami [10]. Sebagai metode pembelajaran terawasi, *decision tree* memprediksi nilai variabel target berdasarkan sejumlah variabel input dan menggabungkan pola serta informasi dalam pohon keputusan [13].

Pada dasarnya, metodologi pohon keputusan yang digunakan untuk klasifikasi kemiripan dengan yang digunakan dalam regresi. Perbedaan utama terletak pada penerapan *Standard Deviation Reduction* (SDR) dalam analisis regresi, sementara pemanfaatan perolehan informasi gain untuk analisis klasifikasi [7]. Terdapat tiga persamaan mendasar yang perlu diperhitungkan ketika menerapkan pohon keputusan dalam konteks regresi (lihat persamaan 1, 2, dan 3)[7][10][5].

$$\mu (\text{mean}) = \frac{\sum_{i=1}^n x_i}{\sum_{i=1}^n f_i} \quad (1)$$

$$\text{Variance} = \frac{\sum_{i=1}^n (x_i - \mu)^2}{n-1} \quad (2)$$

$$\text{Standard Deviation} = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n-1}} \quad (3)$$

Dimana:

- μ = mean atau rata-rata
- n = dimensi data
- i = variabel data
- x = data

Standar deviasi dan varians berfungsi untuk mengukur seberapa tersebar data dalam sebuah distribusi [7]. Jika standar deviasi yang rendah menunjukkan bahwa data berkelompok di sekitar rata-rata, sementara standar deviasi yang tinggi menandakan bahwa data lebih tersebar [10]. Standar deviasi diperoleh dari akar kuadrat varians dan berperan penting dalam menganalisis rata-rata serta variasi data [7].

Dalam penelitian ini, penulis melakukan pemodelan menggunakan algoritma *decision tree regressor* tanpa hyperparameter tuning dan *decision tree regressor* dengan hyperparameter tuning. Hyperparameter Tuning yaitu proses penyetelan parameter sebelum pelatihan untuk meningkatkan kinerja model [8]. Pada algoritma *decision tree*, penyetelan dilakukan menggunakan teknik *RandomizedSearchCV*, yang memungkinkan pencarian

kombinasi parameter secara acak [14]. Teknik ini digunakan untuk menemukan konfigurasi terbaik yang dapat meningkatkan akurasi dan efisiensi model secara keseluruhan [8][14].

2.5. Evaluasi Kinerja

Setelah algoritma *decision tree regressor* diimplementasikan, berikutnya dilakukan evaluasi model menggunakan tiga metrik evaluasi utama, yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *R-squared* (R^2).

- 1) *Mean Absolute Error* (MAE) adalah metrik evaluasi yang digunakan untuk mengukur rata-rata kesalahan absolut antara nilai yang diprediksi oleh model dan nilai actual [15]. MAE menunjukkan seberapa besar rata-rata perbedaan antara hasil prediksi dan nilai sebenarnya, tanpa mempertimbangkan apakah perbedaan tersebut positif atau negative [15][16]. Semakin kecil nilai MAE, semakin baik performa model dalam membuat prediksi [15]. Berikut merupakan rumus MAE:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

Keterangan:

- n = jumlah data atau observasi
- y_i = nilai actual
- \hat{y}_i = nilai yang diprediksi oleh model

- 2) *Root Mean Square Error* (RMSE) adalah matrik evaluasi untuk mengukur rata-rata kesalahan antara nilai yang diprediksi dan nilai actual dalam satuan yang sama dengan data [15]. Semakin rendah nilai RMSE, semakin dekat hasil prediksi model dengan data actual, yang menandakan kinerja model yang lebih baik [15][5]. Berikut merupakan rumus RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

Keterangan:

- n = jumlah data atau observasi
- y_i = nilai actual
- \hat{y}_i = nilai yang diprediksi oleh model

- 3) *R-squared* (R^2) merupakan indikator statistik yang mengukur sejauh mana variabel independen dalam model regresi mampu menjelaskan variasi pada variabel dependen [5]. Nilai R^2 berkisar antara 0 hingga 1, di mana nilai 0 mengindikasikan bahwa model tidak mampu menjelaskan variabilitas variabel dependen, sedangkan nilai 1 menunjukkan bahwa seluruh variabilitas dapat dijelaskan oleh model [5]. Secara umum, semakin tinggi nilai R^2 , semakin baik model regresi dalam menggambarkan varians data [8]. Berikut merupakan rumus *R-squared*:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

Keterangan:

- \bar{y} = rata-rata nilai actual
- y_i = nilai actual
- \hat{y}_i = nilai yang diprediksi oleh model

2.6. Deployment

Setelah pemodelan dan evaluasi kinerja model, langkah selanjutnya adalah *deployment*. *Deployment* model dalam *machine learning* melibatkan pengintegrasian model yang telah dilatih ke dalam lingkungan operasional, sehingga model tersebut dapat menghasilkan prediksi berdasarkan data baru [17]. Dalam penelitian ini, *deployment* adalah tahap implementasi model *Decision Tree* yang telah dilatih ke dalam aplikasi berbasis website

menggunakan Flask. Tahapannya mencakup pengembangan antarmuka pengguna untuk input data dan visualisasi hasil prediksi, integrasi model ke dalam aplikasi, dan pengujian aplikasi untuk memastikan akurasi prediksi serta kemudahan penggunaan.

3. Hasil dan Pembahasan

3.1. Implementasi *Decision Tree*

Penelitian ini menerapkan algoritma *decision tree regressor* untuk memprediksi kebutuhan bahan kain berdasarkan data historis produksi *Threetan Collection*. Dataset yang digunakan terdiri dari 386 *record* dengan 5 fitur utama, yaitu ukuran celana, jenis kain/merk kain, model celana, jumlah pesanan, serta jumlah kain (yard) sebagai variabel target. Data dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian guna mengevaluasi performa model. Pada Gambar 2 menunjukkan dataset setelah melalui tahap *pre-processing*

```

      Size  Jenis Kain/merk kain  Model Celana  Jumlah Pesanan/Hasil produksi
0  0.23873          -0.209457    -0.565146          -0.217638
1  0.23873          -0.209457    -0.565146          -0.217638
2  0.23873          -0.209457    -0.565146          -0.205696
3  0.23873          -0.209457    -0.565146          -0.217638
4  0.23873          -0.209457    -0.565146          -0.205696

```

```

▶ X_train, X_test, y_train, y_test = train_test_split(X_scaled_df, y, test_size=0.2, random_state=123)
X_train.shape, X_test.shape, y_train.shape, y_test.shape
↩ ((308, 4), (78, 4), (308,), (78,))

```

Gambar 2 Dataset setelah melalui tahap *pre-processing*

Penelitian ini menggunakan dua pendekatan dalam membangun model *decision tree regressor*, yaitu tanpa *hyperparameter tuning* dan dengan *hyperparameter tuning* menggunakan *RandomizedSearchCV*. Pendekatan tersebut dilakukan untuk mengukur sejauh mana optimasi parameter mampu meningkatkan kinerja model dalam memprediksi kebutuhan bahan kain di *Threetan Collection*. Hasil evaluasi kinerja dari kedua model ditunjukkan pada Tabel 1, yang membandingkan performa algoritma *Decision Tree Regressor* sebelum dan sesudah *hyperparameter tuning*.

Metric	Tanpa <i>Hyperparameter Tuning</i>	Dengan <i>Hyperparameter Tuning</i>
MAE	2.0272	0.7851
RMSE	7.2421	1.5452
R^2 (R-Squared)	0.8666	0.9862

Berdasarkan hasil evaluasi, model *decision tree regressor* dengan *hyperparameter tuning* menunjukkan peningkatan akurasi yang signifikan dibandingkan model tanpa tuning. MAE turun dari 2.0272 menjadi 0.7851, menunjukkan bahwa rata-rata kesalahan prediksi berkurang hingga di bawah 1 yard, sehingga model mampu memperkirakan kebutuhan kain dengan lebih akurat. Selain itu, RMSE menurun dari 7.2421 menjadi 1.5452, yang menunjukkan bahwa deviasi antara nilai prediksi dan nilai aktual semakin kecil.

Peningkatan paling signifikan terlihat pada R^2 , yang meningkat dari 0.8666 menjadi 0.9862. Hal ini menunjukkan bahwa model dengan tuning dapat menjelaskan 98.62% variabilitas jumlah kain yang digunakan, yang berarti model sangat baik dalam menangkap pola hubungan antara fitur input dan target.

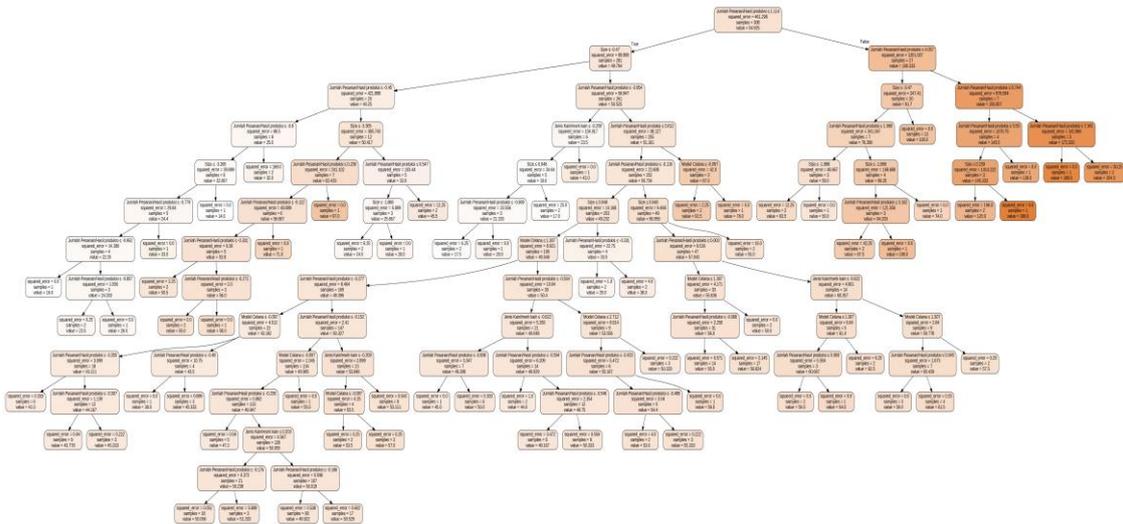
Untuk mencapai peningkatan ini, optimasi *hyperparameter* dilakukan menggunakan *RandomizedSearchCV*, dengan kombinasi parameter terbaik dihasilkan seperti pada Gambar 3. Kombinasi parameter ini membantu model menyeimbangkan bias dan varians, sehingga model tidak hanya bekerja dengan baik pada data pelatihan tetapi juga dapat menggeneralisasi data baru dengan lebih baik. Dengan model yang lebih akurat, *Threetan Collection* dapat

mengoptimalkan perencanaan bahan baku, menghindari kelebihan atau kekurangan stok, serta meningkatkan efisiensi produksi. Pohon keputusan yang terbentuk dapat dilihat pada Gambar 4.

```
[ ] print("Best Parameters:", randomized_search.best_estimator_)
print("Kombinasi parameter terbaik:", randomized_search.best_params_)

Best Parameters: DecisionTreeRegressor(ccp_alpha=0.01, max_depth=13, max_features='sqrt',
min_samples_split=3)
Kombinasi parameter terbaik: {'min_samples_split': 3, 'min_samples_leaf': 1, 'max_features': 'sqrt', 'max_depth': 13, 'ccp_alpha': 0.01}
```

Gambar 3 Hasil Parameter Terbaik



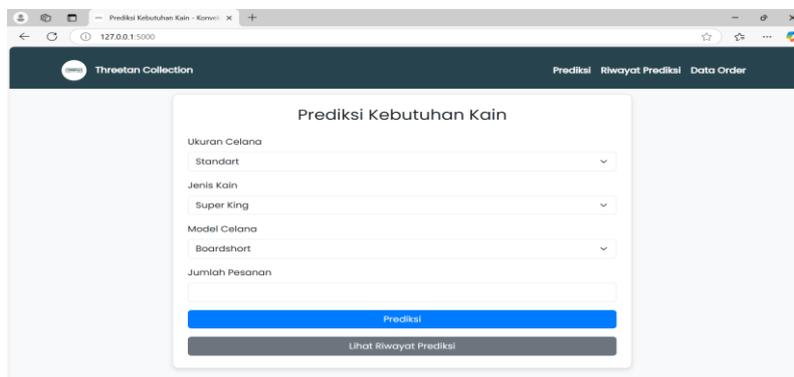
Gambar 4 Pohon Keputusan

3.2. Deployment

Deployment dilakukan agar sistem dapat digunakan oleh pengguna secara lebih praktis, sistem menggunakan model decision tree regressor dengan performa terbaik yang telah dihasilkan. Aplikasi prediksi kebutuhan bahan kain untuk Threetan Collection dikembangkan menggunakan bahasa pemrograman Python dengan framework Flask sebagai antarmuka berbasis web.

1) Halaman Utama Aplikasi

Pada Gambar 5 menunjukkan tampilan halaman utama aplikasi prediksi kebutuhan kain yang telah dibangun. Melalui aplikasi ini, pengguna (pemilik usaha) dapat memprediksi jumlah bahan kain yang dibutuhkan berdasarkan pesanan pelanggan.



Gambar 5 Tampilan Halaman Utama

Dalam proses prediksi, pengguna terlebih dahulu memilih beberapa parameter, yaitu ukuran celana (standart, jumbo, kecil, mini, dan tanggung), jenis kain (super king, FD, NN, twill motif, dan levis), serta model celana (boardshort, chinos pendek, chinos panjang, chinos motif, dan

chinos levis). Selanjutnya, pengguna memasukkan jumlah pesanan, dan sistem akan menampilkan hasil prediksi kebutuhan kain seperti yang ditunjukkan pada Gambar 6.

Gambar 6 Tampilan Hasil Prediksi

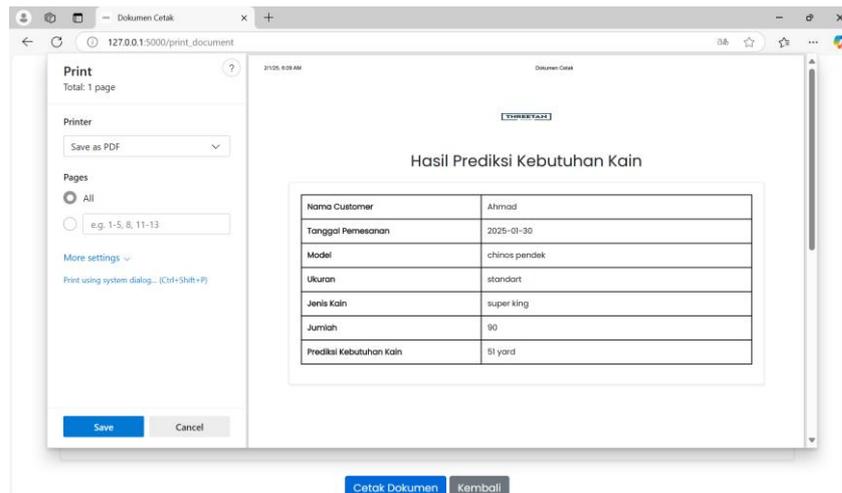
2) Halaman Simpan & Cetak

Selain melakukan prediksi, aplikasi ini juga memiliki fitur penyimpanan data pesanan ke dalam database MySQL. Ketika tombol "Simpan & Cetak" diklik, pengguna dapat memasukkan nama pelanggan dan tanggal pemesanan. Data tersebut akan disimpan ke dalam database MySQL, yang berisi informasi seperti nama pelanggan, tanggal pemesanan, ukuran celana, jenis kain, model celana, jumlah pesanan, dan jumlah kain yang diprediksi.

Gambar 7 Halaman Simpan & Cetak

Nama Customer	Ahmad
Tanggal Pemesanan	2025-01-30
Model	chinos pendek
Ukuran	standart
Jenis Kain	super king
Jumlah	90
Prediksi Kebutuhan Kain	51 yard

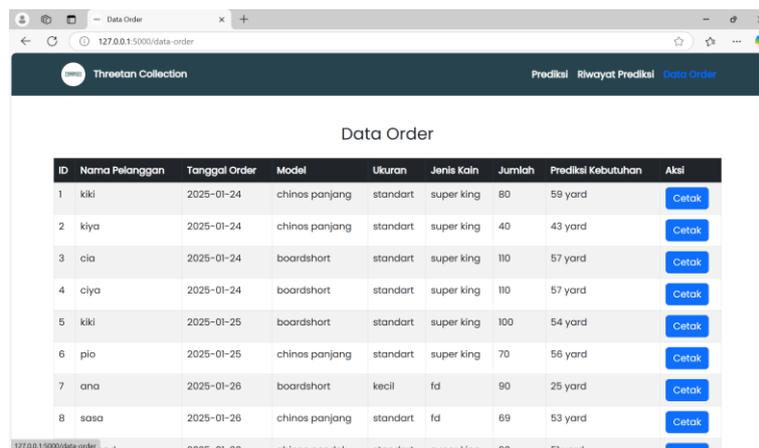
Gambar 8 Halaman Print Dokumen Hasil Prediksi



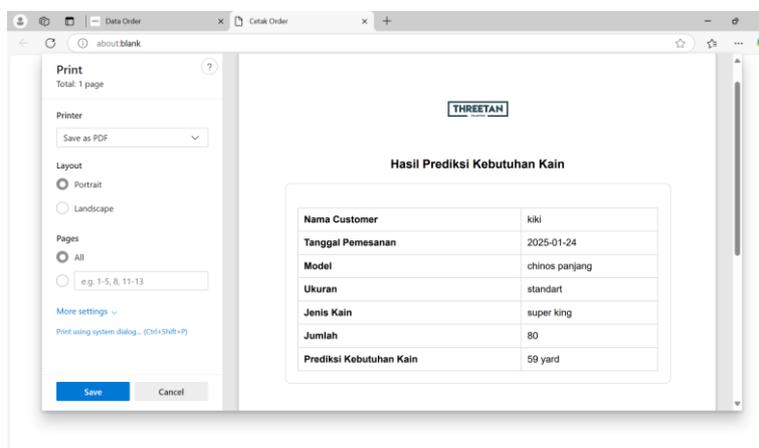
Gambar 9 Halaman Dokumen Siap Cetak

3) Halaman Data Order

Dengan adanya penyimpanan data berbasis MySQL, pemilik usaha dapat dengan mudah mengakses riwayat pesanan melalui antarmuka web. Data pesanan yang tersimpan dapat ditampilkan kembali dalam bentuk tabel dan dapat dicetak sebagai dokumen untuk keperluan administrasi, seperti yang ditunjukkan pada Gambar 10. Fitur ini membantu pemilik usaha dalam mengelola stok bahan kain, menganalisis tren pemesanan, serta meningkatkan efisiensi operasional usaha secara keseluruhan.



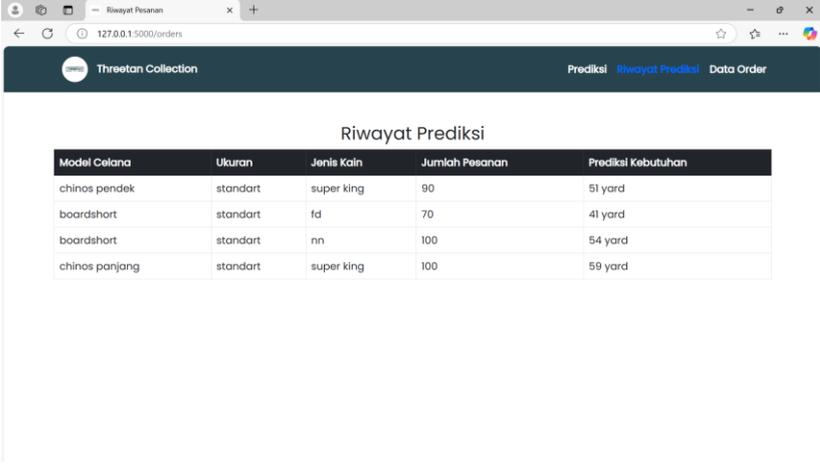
Gambar 10 Halaman Data Order



Gambar 11 Halaman Cetak pada Data Order

4) Halaman Riwayat Prediksi

Pada tampilan Gambar 12, halaman riwayat prediksi menunjukkan data riwayat prediksi yang telah dilakukan (tersimpan sementara dan tidak tersimpan di *database*).



Model Celana	Ukuran	Jenis Kain	Jumlah Pesanan	Prediksi Kebutuhan
chinos pendek	standart	super king	90	51 yard
boardshort	standart	fd	70	41 yard
boardshort	standart	nn	100	54 yard
chinos panjang	standart	super king	100	59 yard

Gambar 12 Halaman Riwayat Prediksi

3.3. Pembahasan

Hasil pengujian menunjukkan bahwa *Decision Tree Regressor* yang telah dioptimasi dengan hyperparameter tuning secara signifikan meningkatkan akurasi prediksi kebutuhan bahan kain di Threetan Collection. R-squared (R^2) meningkat dari 0.8666 menjadi 0.9862, yang berarti model dapat menjelaskan 98.62% variabilitas kebutuhan kain. Selain itu, *Mean Absolute Error* (MAE) berkurang dari 2.0272 menjadi 0.7851, menekan kesalahan prediksi hingga di bawah 1 yard per pesanan. Hasil ini membuktikan bahwa model *Decision Tree* yang dioptimasi lebih andal dalam membantu pemilik usaha mengelola stok bahan secara efisien dan akurat. Sebelum model diterapkan, perkiraan kebutuhan bahan sering kali dilakukan secara manual dengan mengandalkan pengalaman pemilik usaha, yang menyebabkan kelebihan stok hingga dapat mengikat modal usaha yang seharusnya bisa dialokasikan ke keperluan lain. Selain itu, kesalahan estimasi juga menyebabkan kekurangan bahan yang berujung pada keterlambatan produksi dan ketidakpuasan pelanggan. Dengan peningkatan akurasi model dan penurunan tingkat kesalahan prediksi, pemilik usaha kini dapat memperkirakan kebutuhan bahan dengan lebih akurat, sehingga dapat merencanakan pembelian bahan secara lebih efisien, mengoptimalkan penggunaan sumber daya, dan meningkatkan kepuasan pelanggan dengan mengurangi risiko keterlambatan produksi akibat kekurangan bahan.

Hasil ini sejalan dengan penelitian J. Prakash [4], yang menemukan bahwa *Decision Tree* unggul dalam memprediksi ukuran pakaian karena kemampuannya menangkap pola dalam data. Jika penelitian J. Prakash [4] membuktikan bahwa *Decision Tree* unggul dalam menangkap pola ukuran pakaian, penelitian ini membuktikan bahwa metode yang sama juga dapat digunakan dalam perencanaan kebutuhan bahan kain. Dengan kata lain, pola yang berhasil ditemukan oleh *Decision Tree* dalam data ukuran pakaian juga dapat digunakan untuk memprediksi kebutuhan bahan kain dengan akurasi tinggi. Selain itu, penelitian lain telah membuktikan efektivitas *Decision Tree* dalam berbagai bidang, seperti prediksi hasil COVID-19 dan harga saham Apple [5][6], di mana model ini terbukti andal dalam menangani data numerik dan kategorikal. Penelitian ini memperluas penggunaan *Decision Tree* ke dalam industri manufaktur tekstil, yang sebelumnya belum banyak dibahas.

Penelitian ini memberikan dua kontribusi utama dalam bidang prediksi kebutuhan bahan kain menggunakan *Decision Tree*. Pertama, optimasi hyperparameter terbukti meningkatkan akurasi *Decision Tree* hingga 98,62%, mendukung hasil penelitian sebelumnya yang menegaskan keandalan *Decision Tree* dalam prediksi, sekaligus menunjukkan bahwa optimalisasi lebih lanjut dapat semakin meningkatkan performa model. Kedua, penelitian ini mengintegrasikan model ke dalam sistem berbasis aplikasi yang secara langsung dapat digunakan untuk perencanaan stok bahan baku. Studi sebelumnya telah menyoroti keunggulan *Decision Tree* dalam berbagai sektor, tetapi belum banyak yang membahas penerapannya dalam industri tekstil. Dengan demikian, penelitian ini tidak hanya memperkuat efektivitas

Decision Tree dalam prediksi kebutuhan bahan, tetapi juga memperluas cakupan aplikasinya dalam industri manufaktur tekstil, khususnya bagi UMKM konveksi, sehingga dapat memberikan manfaat praktis bagi industri kecil dan menengah.

4. Simpulan

Penelitian ini berhasil mengimplementasikan *Decision Tree Regressor* untuk memprediksi kebutuhan bahan kain pada usaha konveksi Threetan Collection. Hasil evaluasi menunjukkan bahwa optimasi hyperparameter menggunakan *RandomizedSearchCV* meningkatkan akurasi model secara signifikan dibandingkan model tanpa optimasi. Model terbaik yang diperoleh memiliki nilai kesalahan absolut rata-rata atau MAE 0.7851, RMSE 1.5452, dan R^2 0.9862, yang menunjukkan bahwa model mampu menjelaskan 98.62% variabilitas data target dengan tingkat kesalahan yang rendah.

Selain itu, model telah berhasil dideploy dalam aplikasi web berbasis *Flask* dengan penyimpanan data menggunakan MySQL. Aplikasi ini mempermudah pemilik usaha dalam mengelola stok bahan kain, menyimpan riwayat pesanan pelanggan, dan mencetak dokumen prediksi kebutuhan bahan secara otomatis. Dengan demikian, sistem ini berkontribusi dalam meningkatkan efisiensi produksi serta mendukung pengambilan keputusan yang lebih akurat dalam manajemen bahan baku.

Daftar Referensi

- [1] A. Pranata and M. Sihombing, "Analisis Peluang Usaha dalam Upaya Mempertahankan Keberlangsungan Usaha di Tengah Pandemi Covid-19," *J. Soc. Res.*, vol. 1, no. 7, pp. 773–784, 2022, doi: 10.55324/josr.v1i7.150.
- [2] R. Rohmanudin, "Analisis Kebutuhan Bahan Baku Konveksi Dalam Rangka Permintaan Dengan Menggunakan Metode Economic Order Quantity (Eoq) (Studi Kasus Di Ukm Suckseed Konveksi Tasikmalaya).," *J. Ind. Galuh*, vol. 2, no. 2, pp. 80–87, 2020, doi: 10.25157/jig.v2i2.2970.
- [3] C. Atik, A. Kut, D. Birant, and S. Birol, "Prediction of Cloth Waste Using Machine Learning Methods in the Textile Industry," in *International Conference on Electrical and Electronics Engineering (ICEEE)*, 2022, pp. 165–169. doi: 10.1109/ICEEE55327.2022.9772517.
- [4] J. Prakash, V. Nashita, S. S. S, S. Shivathmika, K. Sivesh, and V. Ashwin, "Enhancing Clothing Size Prediction in E-Commerce: A Machine Learning Approach for Improved Customer Experience," *Int. Conf. Smart Syst. Electr. Electron. Commun. Comput. Eng.*, pp. 375–380, 2024, doi: 10.1109/icsseecc61126.2024.10649459.
- [5] A. Fahri and Y. Ramdhani, "Visualisasi Data dan Penerapan Machine Learning Menggunakan Decision Tree Untuk Keputusan Layanan Kesehatan COVID-19," *J. Tekno Kompak*, vol. 17, no. 2, pp. 50–60, 2023, doi: 10.33365/jtk.v17i2.2438.
- [6] Z. Li, "Comparison of Decision Tree Regression with Linear Regression Based on Prediction of Apple Stock Price," *Adv. Econ. Manag. Polit. Sci.*, vol. 45, pp. 62–69, 2023, doi: 10.54254/2754-1169/45/20230259.
- [7] D. E. Waluyo, C. Paramita, H. W. Kinasih, D. Pergiwati, and F. A. Rafrastara, "Aplikasi Prediksi IHSG Berbasis Web Dengan Integrasi Multi-Algoritma," *J. Inform. J. Pengemb. IT*, vol. 9, no. 2, pp. 121–129, 2024, doi: 10.30591/jpit.v9i2.6193.
- [8] M. Sivananda and D. G. K. Kumar, "Classification and Regression Based on Decision Tree Algorithm for Machine Learning," *Indian Sci. J. Res. Eng. Manag.*, vol. 08, no. 02, pp. 1–7, 2024, doi: 10.55041/ijsrem28533.
- [9] H. Zermane, H. MADJOUR, A. Ziar, and H. Zermane, "Forecasting material quantity using machine learning and times series techniques," *J. Electr. Eng.*, vol. 75, no. 3, pp. 237–248, 2024, doi: 10.2478/jee-2024-0029.
- [10] I. Azure, "Predictive modeling for industrial productivity: Evaluating linear regression and decision tree regressor approaches," *J. appliedmath*, vol. 2, no. 4, pp. 1435–1446, 2024, doi: 10.59400/jam.v2i4.1435.
- [11] A. Thabibi and R. Supriyanto, "Perbandingan Model Multiple Linear Regression Dan Decision Tree Regression (Studi Kasus: Prediksi Harga Saham Telkom, Indosat, Dan XI)," *J. Ilm. Teknol. dan Rekayasa*, vol. 28, no. 1, pp. 78–92, 2023, doi: 10.35760/tr.2023.v28i1.6081.
- [12] Dwita Elisa Sinaga, Agus Perdana Windarto, and Rizki Alfadillah Nasution, "Analisis Data Mining Algoritma Decision Tree Pada Prediksi Persediaan Obat (Studi Kasus : Apotek

- Franch Farma),” *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 2, no. 4, pp. 123–131, 2022, doi: 10.30865/klik.v2i4.328.
- [13] H. Asyraf and M. E. Prasetya, “Implementasi Metode CRISP DM dan Algoritma Decision Tree Untuk Strategi Produksi Kerajinan Tangan pada UMKM A,” *J. Media Inform. Budidarma*, vol. 8, no. 1, pp. 94–105, 2024, doi: 10.30865/mib.v8i1.7050.
- [14] N. Alamsyah, B. Budiman, T. P. Yoga, and R. Y. R. Alamsyah, “Xgboost hyperparameter optimization using randomizedsearchcv for accurate forest fire drought condition prediction,” *Pilar Nusa Mandiri J. Comput. Inf. Syst.*, vol. 20, pp. 103–110, 2024, doi: 10.33480/pilar.v20i2.5569.
- [15] I. Indriyanti, N. Ichsan, H. Fatah, T. Wahyuni, and E. Ermawati, “Implementasi Orange Data Mining Untuk Prediksi Harga Bitcoin,” *J. Responsif Ris. Sains dan Inform.*, vol. 4, no. 2, pp. 118–125, 2022, doi: 10.51977/jti.v4i2.762.
- [16] N. Almajid, Y. R. Ginting, and A. I. Ramadhan, “Penerapan Decision Tree Regression dalam Memprediksi Harga Rumah di Provinsi Jawa Barat,” *J. Ris. Inform. dan Teknol. Inf.*, vol. 1, no. 3, pp. 111–115, 2024, doi: 10.58776/jriti.v1i3.64.
- [17] N. E. Vijayan, “Building Scalable MLOps: Optimizing Machine Learning Deployment and Operations,” *Indian Sci. J. Res. Eng. Manag.*, vol. 08, no. 10, pp. 1–9, 2024, doi: 10.55041/ijsrem37784.