

Analisis Feature Importance Variabel Gap SMV dan Manpower terhadap Output Produksi Garmen berbasis Ensemble Learning

Feature Importance Analysis of SMV Gap and Manpower Variables on Garment Production Output based on Ensemble Learning

¹Heni Candra Kirana*, ²Eka Ardhianto

^{1,2}Program Studi Teknologi Informasi, Fakultas Teknologi Informasi dan Industri, Universitas Stikubank Semarang

^{1,2}Jl. Tri Lomba Juang, Mugassari, Semarang, Kota Semarang, Jawa Tengah 50243, Indonesia
*e-mail: henicandra0004@mhs.unisbank.ac.id

(received: 26 April 2026, revised: 4 May 2026, accepted: 5 May 2026)

Abstrak

Dalam industri manufaktur garmen yang padat karya, terdapat asumsi konvensional bahwa pencapaian target produksi sangat bergantung pada penambahan jumlah tenaga kerja (*manpower*), sehingga evaluasi terhadap efisiensi waktu operasional sering dikesampingkan. Untuk menguji asumsi tersebut, penelitian ini bertujuan mengidentifikasi faktor dominan yang memengaruhi output produksi garmen menggunakan pendekatan *Machine Learning* berbasis *Ensemble Learning* (*Random Forest* dan *Gradient Boosting*). Data yang digunakan sebanyak 700 observasi dengan interval 20 menit, mencakup variabel *Standard Minute Value* (SMV) aktual, *gap* SMV, *manpower* aktual, dan *gap* *manpower*. Hasil evaluasi menunjukkan bahwa *Random Forest* memiliki kinerja lebih baik dengan nilai *Mean Absolute Error* (MAE) sebesar 4,55, *Root Mean Square Error* (RMSE) 6,85, *Mean Absolute Percentage Error* (MAPE) 19,12%, dan R^2 0,758, dibandingkan *Gradient Boosting* yang memperoleh MAE sebesar 4,88, RMSE 7,21, MAPE 20,78%, dan R^2 0,733. Mengacu pada performa model terbaik tersebut, analisis *feature importance* menunjukkan bahwa SMV aktual merupakan faktor paling dominan ($>0,70$), diikuti *gap* SMV ($>0,20$). Sebaliknya, variabel *manpower* memiliki pengaruh yang sangat rendah ($<0,05$). Berbeda dengan studi terdahulu yang umumnya berfokus pada optimasi kuantitas pekerja, kebaruan (*novelty*) penelitian ini terletak pada penggunaan variabel *gap* SMV dan *gap* *manpower* secara bersamaan dalam model prediktif, yang memberikan kontribusi empiris bahwa kompleksitas pekerjaan dan efisiensi waktu operasional jauh lebih krusial dalam menentukan capaian output garmen dibandingkan sekadar penambahan tenaga kerja.

Kata kunci: *feature importance, gradient boosting, industrial analytics, machine learning regression, random forest*

Abstract

In the labor-intensive garment manufacturing industry, there is a conventional assumption that achieving production targets largely depends on increasing the number of workers (manpower), causing evaluations of operational time efficiency to often be overlooked. To examine this assumption, this study aims to identify the dominant factors affecting garment production output using a Machine Learning approach based on Ensemble Learning methods, namely Random Forest and Gradient Boosting. The dataset consisted of 700 observations collected at 20-minute intervals, including variables such as actual Standard Minute Value (SMV), SMV gap, actual manpower, and manpower gap. The evaluation results indicate that the Random Forest model outperformed Gradient Boosting, achieving a Mean Absolute Error (MAE) of 4.55, Root Mean Square Error (RMSE) of 6.85, Mean Absolute Percentage Error (MAPE) of 19.12%, and an R^2 value of 0.758. In comparison, Gradient Boosting obtained an MAE of 4.88, RMSE of 7.21, MAPE of 20.78%, and an R^2 value of 0.733. Based on the best-performing model, the feature importance analysis revealed that actual SMV was the most dominant factor (>0.70), followed by the SMV gap (>0.20). In contrast, manpower variables had a very limited influence (<0.05). Unlike previous studies that generally focused on optimizing the number of workers, the novelty of this research lies in the simultaneous use of SMV gap and

<http://sistemasi.ftik.unisi.ac.id>

manpower gap variables within a predictive model. This approach provides empirical evidence that job complexity and operational time efficiency are significantly more critical in determining garment production output than merely increasing the workforce.

Keywords: *feature importance, gradient boosting, industrial analytics, machine learning regression, random forest*

1 Pendahuluan

Perkembangan teknologi digital dalam era Industri 4.0 mendorong sektor manufaktur, termasuk industri garmen, untuk mengadopsi pendekatan pengambilan keputusan berbasis data (*data-driven decision making*) [1]. Sebagai industri padat karya, memprediksi output produksi secara presisi adalah faktor krusial untuk menjaga daya saing perusahaan. Perencanaan produksi yang tidak akurat sering kali memicu inefisiensi operasional, seperti alokasi jam lembur yang membengkak tanpa diiringi peningkatan produktivitas yang berarti [2], [3].

Dalam praktiknya, *Standard Minute Value* (SMV) digunakan sebagai acuan waktu standar dalam proses produksi garmen. Namun, deviasi antara nilai standar dan kondisi aktual di lapangan (*gap SMV*) sering kali menjadi sumber ketidakpastian output produksi. Di sisi lain, faktor tenaga kerja (*manpower*) juga dianggap sebagai variabel penentu utama. Meskipun demikian, penambahan jumlah *manpower* secara kuantitatif tidak selalu berbanding lurus dengan peningkatan output, terutama ketika efisiensi proses kerja tidak dikelola dengan baik [4]. Hal ini menimbulkan urgensi untuk memetakan kembali variabel mana yang sebenarnya memberikan dampak paling signifikan terhadap performa lini produksi.

Sejumlah penelitian terdahulu telah mengkaji berbagai faktor yang memengaruhi produksi garmen [4]. Namun, terdapat celah penelitian (*research gap*) di mana sebagian besar studi, seperti yang dilakukan oleh Azizah dan Isfianadewi [5] masih menganalisis variabel SMV dan *manpower* secara terpisah dan belum mengintegrasikannya dalam sebuah model prediktif yang komprehensif. Selain itu, pemanfaatan metode *Machine Learning* untuk mengidentifikasi tingkat kepentingan masing-masing variabel (*feature importance*) dalam konteks operasional garmen masih relatif terbatas [6].

Guna mengisi celah tersebut, penelitian ini mengusulkan pendekatan *Machine Learning* berbasis algoritma *ensemble tree*, yaitu *Random Forest* dan *Gradient Boosting*. Penggunaan algoritma ini didasarkan pada kemampuannya dalam memodelkan hubungan non-linear dari data manufaktur yang dinamis, sekaligus mampu mengekstrak tingkat kepentingan masing-masing variabel melalui analisis *feature importance*. Berbeda dengan studi terdahulu [5], keunggulan utama dari model yang diusulkan terletak pada kemampuannya untuk mengintegrasikan variabel aktual dan variabel *gap* (baik SMV maupun *manpower*) secara terpadu. Pendekatan ini memungkinkan prediksi output yang presisi sekaligus memberikan interpretasi fitur yang komprehensif.

Berdasarkan uraian latar belakang tersebut, penelitian ini diarahkan untuk menjawab pertanyaan penelitian berikut:

1. Bagaimana perbandingan tingkat akurasi kinerja algoritma *Random Forest* dan *Gradient Boosting* dalam memprediksi output produksi garmen?
2. Berdasarkan analisis *feature importance*, variabel manakah yang paling dominan (SMV aktual, *gap SMV*, *manpower* aktual, atau *gap manpower*) dalam memengaruhi capaian output produksi?

Sejalan dengan rumusan masalah di atas, penelitian ini bertujuan untuk mengevaluasi sekaligus membandingkan kinerja model *Random Forest* dan *Gradient Boosting* dalam memprediksi output produksi, serta mengidentifikasi faktor yang paling dominan melalui analisis *feature importance*. Secara signifikan, hasil penelitian ini diharapkan dapat memberikan kontribusi dalam penerapan kecerdasan buatan di industri, sekaligus memberikan manfaat praktis sebagai dasar pengambilan keputusan yang lebih objektif dan terukur bagi pihak manajemen dalam perencanaan produksi berbasis data.

2 Tinjauan Literatur

Dinamika efisiensi lini industri garmen sering kali diukur melalui deviasi antara standar waktu teoritis dan aktual lapangan. Beberapa studi terdahulu menegaskan bahwa keberadaan *gap SMV*

berbanding terbalik dengan capaian output harian, di mana inefisiensi proses menjadi konsekuensi langsung dari kegagalan sinkronisasi waktu operasional [7], [8]. Urgensi pengendalian deviasi waktu ini telah dibuktikan sebagai kunci utama dalam menjaga konsistensi target produksi [5]. Namun, evaluasi waktu standar saja dinilai tidak mencukupi mengingat karakteristik industri garmen yang padat karya. Literatur lain mengungkapkan bahwa pengaruh tenaga kerja (*manpower*) terhadap output produksi tidak bersifat linear sederhana. Hal ini dikarenakan stabilitas performa operator ditemukan sebagai faktor penentu yang lebih dominan dibandingkan sekadar penambahan jumlah tenaga kerja secara kuantitatif [9], [4].

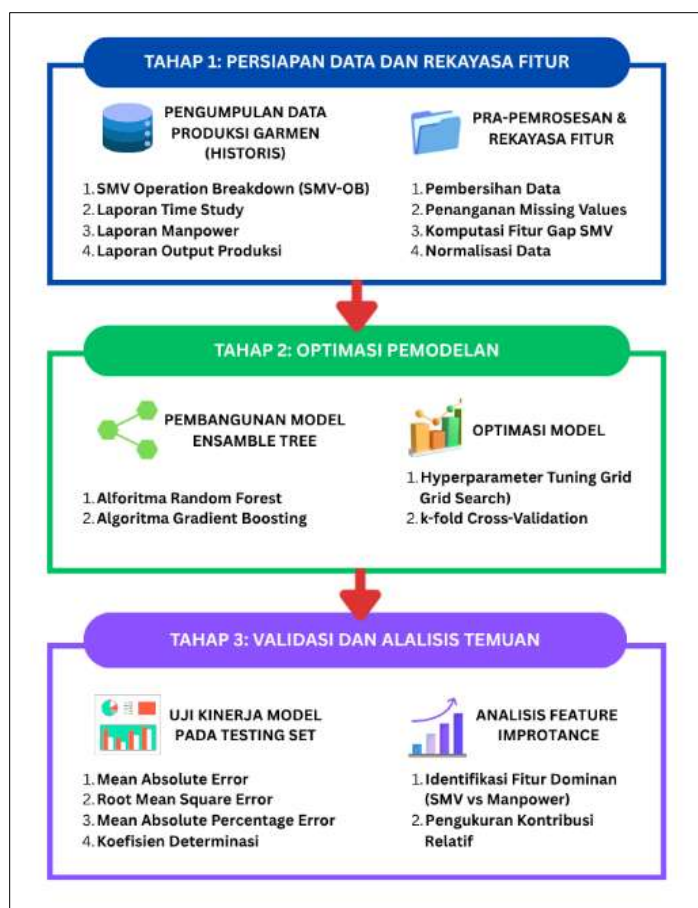
Penerapan model regresi konvensional seringkali menghadapi kendala dalam memetakan pola produksi yang bersifat non-linear, sehingga penggunaan algoritma berbasis *ensemble tree* menjadi solusi untuk meningkatkan akurasi estimasi produksi secara signifikan [10]. Dalam spektrum algoritma *ensemble*, *Random Forest* dan *Gradient Boosting* menonjol karena kemampuannya menangani derau (*noise*) data melalui pendekatan arsitektur yang berbeda [11]. Riset terbaru oleh Amrulloh dkk. [12] memperkuat argumen ini dengan menunjukkan bahwa optimasi algoritma *Random Forest* mampu memberikan hasil klasifikasi produktivitas yang sangat stabil di industri garmen. Sejalan dengan hal tersebut, integrasi antara *machine learning* dengan optimasi alokasi sumber daya juga terbukti efektif dalam meminimalisir *gap* antara target dan realisasi produksi di lingkungan industri garmen [13].

Random Forest bekerja dengan mekanisme *parallel bagging*, yakni mengagregasi banyak pohon keputusan secara paralel untuk meminimalkan varians dan mengidentifikasi penggerak produktivitas yang signifikan [14]. Sebaliknya, *Gradient Boosting* menawarkan ketangguhan dalam mengoreksi kesalahan prediksi secara sekuensial dan iteratif, yang terbukti sangat efektif untuk mendeteksi pola anomali pada data rantai produksi yang kompleks [15].

Meskipun pemanfaatan *Machine Learning* terus berkembang pesat di sektor manufaktur, sebagian besar studi masih berfokus pada ranah pasca-produksi, seperti peramalan rantai pasok atau otomatisasi kontrol kualitas [16]. Namun demikian, integrasi model prediktif pada proses inti manufaktur sangat krusial untuk menangani sistem produksi yang kompleks dan intensif data [17]. Selain itu, banyak penelitian hanya berfokus pada pencapaian akurasi model tanpa membedah kontribusi spesifik dari tiap variabel operasional [11]. Oleh karena itu, terdapat celah penelitian (*research gap*) yang nyata terkait integrasi variabel metrik waktu (*gap SMV*) dan fluktuasi tenaga kerja (*gap manpower*) secara terpadu dalam satu model prediktif yang komprehensif. Penelitian ini hadir untuk mengisi kekosongan tersebut dengan menggunakan teknik *feature importance* guna membuktikan secara empiris apakah besaran deviasi standar waktu atau jumlah tenaga kerja yang sebenarnya menjadi faktor penentu utama output produksi garmen.

3 Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimental berbasis *Machine Learning Regressor*. Secara sistematis, alur kerja penelitian ini dibagi menjadi tiga tahapan utama yang saling terintegrasi, sebagaimana diilustrasikan pada Gambar 1.



Gambar 1 Kerangka alur penelitian

3.1 Pengumpulan Data, Prapemrosesan, dan Rekayasa Fitur

Populasi penelitian mencakup seluruh aktivitas pada lini sewing garmen. Sampel ditentukan menggunakan teknik *purposive sampling* guna memastikan kelengkapan instrumen variabel prediktor. *Dataset* yang dianalisis berjumlah 700 observasi historis dengan interval perekaman setiap 20 menit. Sebelum memasuki tahap pemodelan, *dataset* terlebih dahulu melalui tahapan prapemrosesan data (*data preprocessing*) secara berurutan untuk memastikan kualitasnya. Tahap pertama adalah identifikasi nilai yang hilang (*missing values*) dan duplikasi observasi. Hasil rekapitulasi menunjukkan bahwa seluruh 700 observasi merupakan data yang lengkap dan siap diolah.

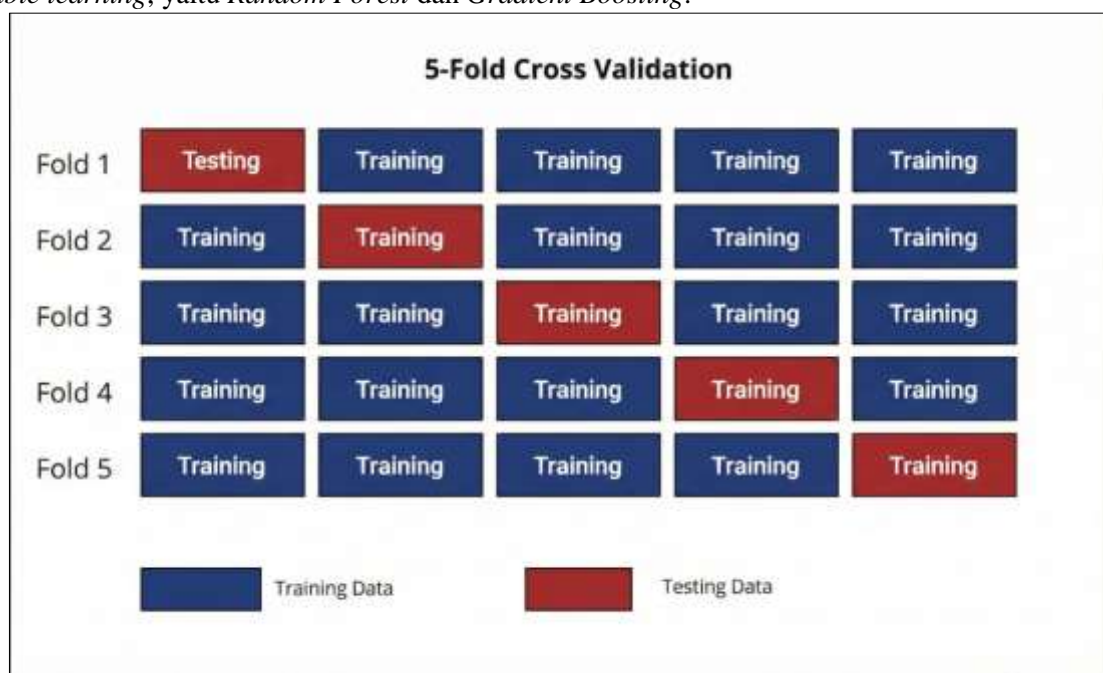
Tahap kedua adalah penanganan data ekstrem, yaitu nilai yang menyimpang sangat jauh dari pola umumnya. Data ekstrem tersebut tidak dihapus atau dibuang dikarenakan lonjakan angka yang tidak wajar seperti tingkat kerumitan menjahit (SMV) yang tiba tiba melambung sangat tinggi justru merepresentasikan kejadian nyata dan kendala anomali di rantai produksi, misalnya ketika terjadi pergantian model pakaian (*style*) secara mendadak. Selanjutnya, karena algoritma yang digunakan (*Random Forest* dan *Gradient Boosting*) sangat tangguh dan tidak sensitif terhadap perbedaan skala angka antar variabel, maka tahap penyamaan skala data (*data scaling*) tidak dilakukan. Keputusan ini diambil guna menjaga keaslian nilai variabel agar hasil akhirnya tetap mudah dibaca.

Dalam model ini, capaian output produksi ditetapkan sebagai variabel dependen (y), sementara variabel independen (x) meliputi SMV aktual, *manpower* aktual, *gap manpower*, dan *gap SMV*. Untuk merepresentasikan kondisi inefisiensi riil di lapangan, dilakukan teknik rekayasa fitur (*feature engineering*) pada variabel *gap SMV* dengan menghitung selisih antara SMV aktual (hasil *time study*) dengan SMV teoritis (berdasarkan *Operation Breakdown*). Fitur rekayasa ini dinilai lebih representatif dalam mengukur deviasi efisiensi operasional dibandingkan data mentah [8].

3.2 Pengembangan Model dan Tuning Hyperparameter

Dataset dipartisi secara acak menjadi data latih (80%) dan data uji (20%). Data latih digunakan untuk mempelajari pola hubungan antara variabel prediktor terhadap output, sedangkan data uji disimpan terpisah untuk memvalidasi kemampuan generalisasi model terhadap data yang belum

pernah dipelajari sebelumnya. Pemodelan komparatif dilakukan menggunakan dua algoritma *ensemble learning*, yaitu *Random Forest* dan *Gradient Boosting*.



Gambar 2 Skema *K-Fold cross validation* ($k = 5$)

Gambar 2 menyajikan ilustrasi mekanisme *k-Fold Cross Validation* yang diimplementasikan dalam tahap optimasi model. Pada skema ini, dataset dibagi secara sistematis menjadi lima bagian atau *fold* dengan ukuran yang sama besar. Dalam setiap iterasi yang mencakup *Fold 1* hingga *Fold 5*, terdapat satu bagian data yang dialokasikan sebagai data uji atau *testing* data yang ditandai dengan kotak berwarna merah, sementara empat bagian sisanya berfungsi sebagai data latih atau *training* data yang ditandai dengan kotak berwarna biru. Proses evaluasi ini dilakukan secara berulang sebanyak lima kali guna memastikan setiap bagian data mendapatkan kesempatan satu kali untuk menjadi validator.

Guna mencegah terjadinya *overfitting* dan memastikan stabilitas model, proses pelatihan dioptimasi menggunakan metode *Grid Search* yang dikombinasikan dengan *k-fold Cross-Validation*. Penelitian ini menetapkan nilai $k = 5$ sebagai titik kompromi optimal dalam keseimbangan *bias-varians* (*bias-variance tradeoff*). Nilai $k = 5$ yang moderat dipilih untuk menghasilkan estimasi performa model yang stabil serta meminimalkan risiko *overfitting* maupun *underfitting*. Selain itu, pemilihan ini mempertimbangkan efisiensi komputasi pada dataset berukuran menengah guna menghindari peningkatan kompleksitas yang tidak diperlukan [18]. Proses ini dilakukan menggunakan bahasa pemrograman *Python* untuk mencari kombinasi *hyperparameter* paling optimal, seperti jumlah pohon ($n_estimators$) dan kedalaman maksimal (max_depth) [19].

3.3 Evaluasi dan Identifikasi Fitur Dominan

Evaluasi performa model diukur secara kuantitatif menggunakan empat metrik regresi standar untuk memberikan penilaian komprehensif terhadap keandalan model pada lingkungan produksi yang dinamis [20]. Adapun metrik yang digunakan adalah sebagai berikut:

1. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi. Metrik ini bersifat intuitif karena memberikan bobot merata pada seluruh kesalahan tanpa memperbesar dampak nilai ekstrem [21]. Nilai MAE yang rendah merepresentasikan tingkat kesalahan rata-rata yang kecil, sebagaimana dirumuskan pada persamaan (1):

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

2. Root Mean Square Error (RMSE)

Berbeda dengan MAE, RMSE memberikan bobot lebih besar pada kesalahan yang signifikan karena melalui proses penguadratan selisih sebelum diakarkan. Sifat RMSE yang sensitif terhadap outlier sangat efektif untuk mendeteksi apakah model menghasilkan prediksi yang meleset jauh [21]. Perhitungan RMSE dilakukan melalui akar kuadrat dari rata-rata kuadrat selisih antara nilai aktual dan prediksi, yang dirumuskan dalam persamaan (2).

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

3. Mean Absolute Percentage Error (MAPE)

Metrik ketiga adalah *Mean Absolute Percentage Error* (MAPE). Sesuai dengan persamaan (3), metrik ini menunjukkan persentase rata-rata penyimpangan prediksi terhadap nilai aktual, yang mempermudah interpretasi tingkat kesalahan dalam skala relatif atau persentase.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3)$$

4. Koefisien Determinasi (R^2)

Koefisien determinasi digunakan untuk mengukur sejauh mana varians pada variabel dependen dapat dijelaskan oleh variabel independen dalam model. Nilai R^2 yang mendekati satu menunjukkan tingkat kecocokan yang sangat baik, di mana model mampu menangkap pola hubungan antar variabel secara akurat. Metrik ini dihitung menggunakan persamaan (4):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (4)$$

Keterangan:

n : Jumlah total observasi (700 data)

y_i : Nilai output produksi aktual pada observasi ke- i

\hat{y}_i : Nilai output hasil prediksi model

\bar{y}_i : Rata-rata nilai output produksi dari seluruh data aktual

Setelah model dengan performa terbaik diidentifikasi, tahap akhir adalah melakukan analisis *Feature Importance*. Analisis ini bertujuan untuk mengukur kontribusi relatif dari masing-masing prediktor terhadap fluktuasi output produksi, sehingga menghasilkan temuan yang dapat diinterpretasikan untuk pengambilan keputusan manajerial [22].

4 Hasil dan Pembahasan


4.1 Karakteristik Data dan Analisis Hubungan Variabel

Tahap awal analisis dilakukan dengan membedah karakteristik statistik dari 700 observasi data operasional garmen. Ringkasan statistik deskriptif pada Tabel 1 menunjukkan variabilitas yang tinggi pada variabel *smv_aktual* (3,75 hingga 128,38), mencerminkan keragaman kompleksitas desain produk di lini produksi.

Tabel 1 Statistik deskriptif variabel penelitian

Variabel	Rata-Rata	Std Dev	Min	Median	Max
gap_smv	4,71	7,88	-23,68	2,76	77,04
manpower_aktual	39,61	4,69	4,00	40,00	63,00
gap_manpower	-2,66	4,84	-39,00	-2,00	36,00
smv_aktual	25,29	12,40	3,75	23,80	128,38
output_aktual	29,21	18,10	2,00	25,00	220,00

Untuk memahami interaksi antar variabel, dilakukan uji korelasi yang divisualisasikan melalui *Heatmap* pada Gambar 3.



Gambar 3 Heatmap matriks korelasi antar variabel

Berdasarkan Gambar 3, ditemukan bahwa gap_smv memiliki korelasi negatif yang paling signifikan terhadap output_aktual (-0,46). Hal ini membuktikan secara empiris bahwa inefisiensi waktu pengerjaan berbanding terbalik dengan capaian target. Sebaliknya, korelasi manpower_aktual terhadap output sangat lemah (-0,13), menegaskan bahwa penambahan tenaga kerja bukan solusi utama untuk meningkatkan output pada kondisi data ini.

4.2 Evaluasi Kinerja Model Ensemble

Sebelum mengidentifikasi fitur dominan, dilakukan evaluasi untuk memastikan model memiliki tingkat kepercayaan yang tinggi. Perbandingan kinerja antara *Random Forest* dan *Gradient Boosting* disajikan pada Tabel 2.

Tabel 2 Perbandingan kinerja model

Metrik Evaluasi	<i>Random Forest</i>	<i>Gradient Boosting</i>
MAE (<i>Mean Absolute Error</i>)	4,55	4,88
RMSE (<i>Root Mean Square Error</i>)	6,85	7,21
MAPE (<i>Mean Absolute Percentage Error</i>)	19,12%	20,78%
R ² Score (Akurasi)	0,758	0,733

Model *Random Forest* dipilih sebagai basis analisis fitur karena berdasarkan Tabel 2, *Random Forest* mengungguli *Gradient Boosting* pada seluruh metrik pengujian. *Random Forest* mencatatkan tingkat kesalahan yang lebih rendah dengan nilai MAE 4,55, RMSE 6,85, dan MAPE 19,12%, sementara *Gradient Boosting* menghasilkan tingkat kesalahan yang sedikit lebih tinggi dengan MAE 4,88, RMSE 7,21, dan MAPE 20,78%.

Selain itu, *Random Forest* mencapai nilai koefisien determinasi (R²) yang lebih tinggi sebesar 0,758 dibandingkan *Gradient Boosting* yang sebesar 0,733. Hal ini menunjukkan bahwa *Random Forest* mampu menjelaskan 75,8% variabilitas output produksi, sedangkan *Gradient Boosting* hanya mampu menjelaskan 73,3%. Sisa variansi sebesar 24,2% pada model terpilih diasumsikan berasal dari faktor eksternal di luar pemodelan, seperti kelelahan operator atau kendala teknis mesin di lapangan.

4.3 Validasi Stabilitas Model (*K-Fold Cross Validation*)

Untuk memastikan stabilitas performa dan menghindari *overfitting*, dilakukan validasi silang menggunakan metode *5-Fold Cross Validation*.

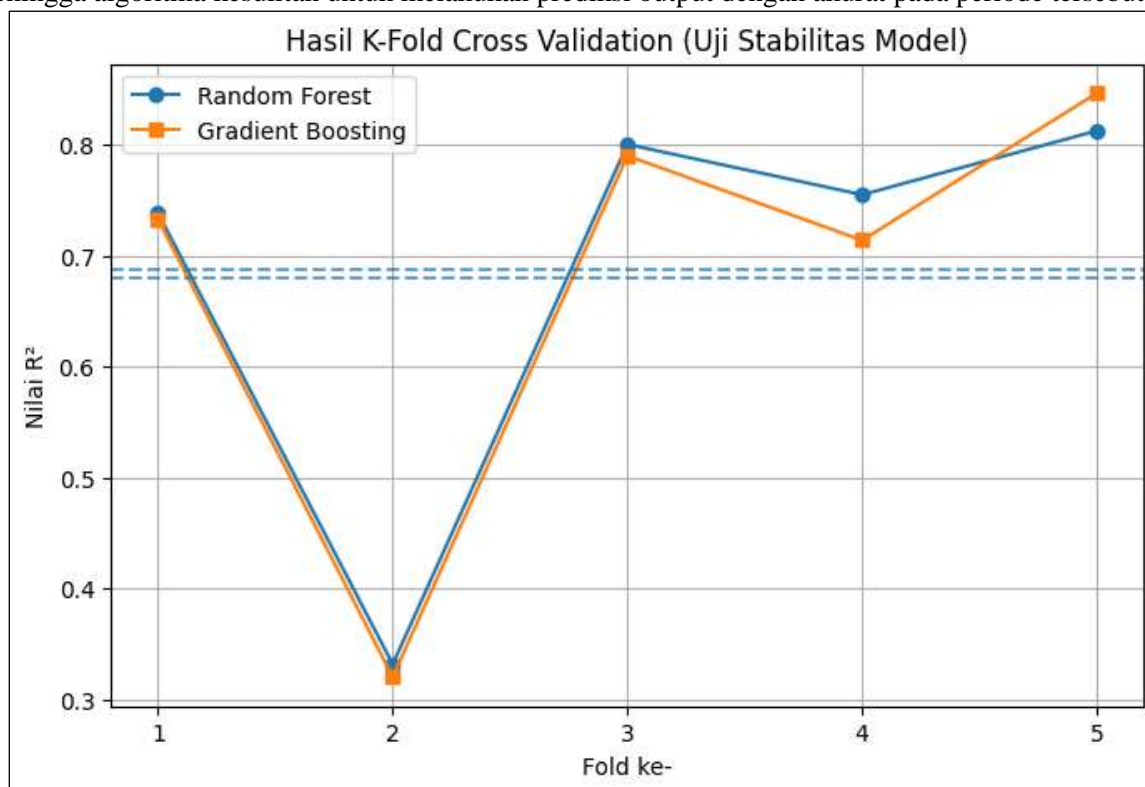
Tabel 3 Hasil K-Fold cross validation model (R²)

Model	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Mean R ²	Std Dev
Random Forest	0,7338	0,3317	0,8002	0,7549	0,8125	0,6875	0,1800
Gradient Boosting	0,7326	0,3283	0,7899	0,7138	0,8464	0,6886	0,1860

Berdasarkan hasil pada Tabel 3, kedua model menunjukkan performa yang sangat kompetitif. Meskipun *Gradient Boosting* mencatat rata-rata R² yang sedikit lebih tinggi (0,6886) dibandingkan *Random Forest* (0,6875), selisih tersebut sangat tidak signifikan (<0,001). Namun, dari aspek konsistensi, *Random Forest* terbukti lebih unggul dengan nilai standar deviasi yang lebih rendah (0,1800) dibandingkan *Gradient Boosting* (0,1860). Hal ini menunjukkan bahwa *Random Forest* memiliki tingkat variabilitas yang lebih kecil dan lebih stabil dalam menghadapi fluktuasi data.

Perbedaan nilai R² antara pengujian *hold-out* (0,758) dan rata-rata *cross-validation* (0,6875) terjadi karena karakteristik dari metode pengujian itu sendiri. Pengujian *hold-out* hanya mengevaluasi satu bagian data secara acak, yang kebetulan memiliki pola data yang teratur dan ideal. Sebaliknya, *cross-validation* menguji model pada seluruh bagian dataset secara bergantian, termasuk pada periode waktu di mana kondisi garmen sedang tidak stabil. Hal ini membuktikan bahwa operasional garmen memiliki fluktuasi dan dinamika yang tinggi dari waktu ke waktu.

Ketidakstabilan ini paling jelas terlihat pada pengujian fold ke-2, di mana performa model mengalami anjlok yang ekstrem ke angka 0,33. Secara operasional, anomali pada *fold* ini mencerminkan kondisi *riil* di lini produksi yang sedang sangat tidak menentu. Hal ini terjadi karena adanya perubahan gaya (*style*) pakaian yang mendadak, atau lini produksi dipaksa mengerjakan desain dengan tingkat kerumitan yang sangat tinggi (ditandai dengan nilai *smv_aktual* yang melonjak hingga batas atas 128,38). Kondisi produksi yang dinamis ini membuat pola data menjadi sangat acak, sehingga algoritma kesulitan untuk melakukan prediksi output dengan akurat pada periode tersebut.

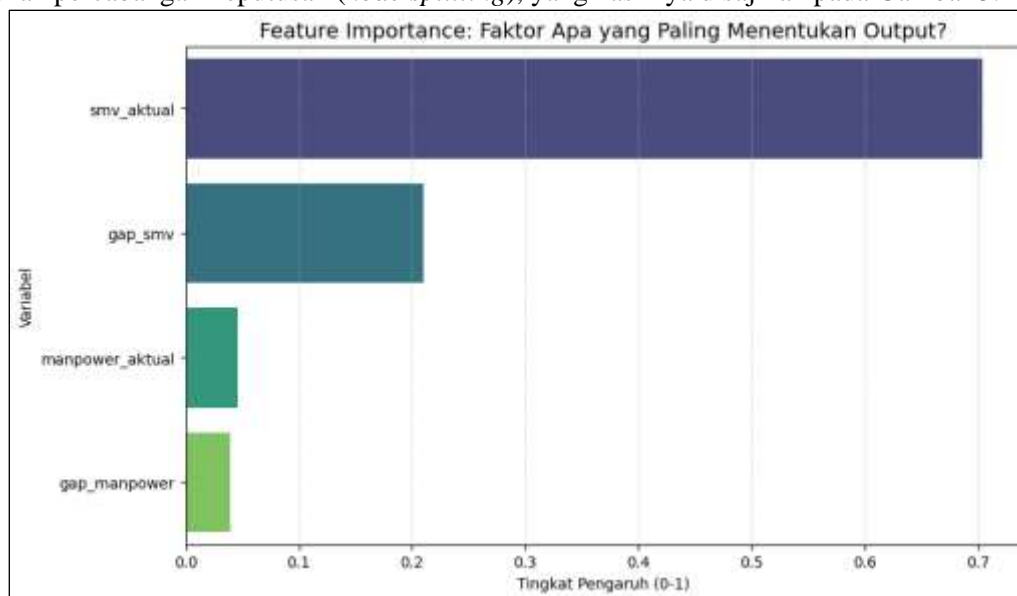


Gambar 4 Visualisasi distribusi validasi silang

Secara visual, distribusi akurasi pada Gambar 4 (*Box Plot*) mempertegas bahwa meskipun terdapat rentang variasi akibat anomali data, *Random Forest* memiliki sebaran data yang lebih stabil. Dengan mempertimbangkan stabilitas validasi silang serta nilai *error* absolut (RMSE dan MAE) yang lebih rendah pada pengujian awal, *Random Forest* ditetapkan sebagai model utama dalam penelitian ini karena dinilai lebih andal untuk pengambilan keputusan di lapangan.

4.4 Analisis Fitur Dominan (*Feature Importance*)

Identifikasi fitur dominan dilakukan untuk memetakan variabel yang paling memengaruhi fluktuasi output. Analisis ini mengukur kontribusi setiap variabel input saat algoritma *Random Forest* melakukan percabangan keputusan (*node splitting*), yang hasilnya disajikan pada Gambar 5.



Gambar 5 Tingkat kepentingan fitur (*feature importance*)

Berdasarkan Gambar 5 secara konsisten menunjukkan bahwa *smv_aktual* adalah fitur paling dominan dengan skor kepentingan di atas 0,70. Hal ini memberikan bukti kuat bahwa tingkat kesulitan model produk adalah penentu utama kapasitas produksi harian. Faktor kedua adalah *gap_smv* ($>0,20$), yang mewakili efisiensi teknis operator. Sementara itu, faktor *manpower* memiliki kontribusi yang sangat rendah ($<0,05$), mengindikasikan adanya inefisiensi pada metode kerja yang tidak dapat diselesaikan hanya dengan penambahan tenaga kerja.

4.5 Pembahasan

Berdasarkan hasil visualisasi *feature importance* pada model terbaik, ditemukan bahwa faktor-faktor yang memengaruhi output produksi memiliki hierarki kontribusi yang signifikan. Pertama, variabel *smv_aktual* teridentifikasi sebagai faktor paling dominan dengan skor signifikansi di atas 0,70. Dominansi SMV ini menunjukkan bahwa tingkat kesulitan sebuah produk merupakan determinan utama dalam menentukan jumlah output. Secara teknis, semakin tinggi nilai SMV maka output yang dihasilkan dalam satu satuan waktu akan semakin menurun. Temuan ini memberikan bukti empiris bahwa fluktuasi produksi pada objek penelitian lebih banyak dipengaruhi oleh variasi model pakaian dibandingkan jumlah tenaga kerja yang tersedia.

Kedua, variabel *gap_smv* menempati posisi signifikansi berikutnya dengan skor di atas 0,20. Hal ini menegaskan bahwa efisiensi di lapangan, atau tingkat presisi antara waktu kerja nyata terhadap standar teoritis, menjadi penentu penting kedua. Implikasi dari temuan ini menunjukkan bahwa meskipun lini produksi menangani model pakaian dengan tingkat kerumitan rendah (SMV rendah), capaian output tetap tidak akan maksimal apabila terjadi inefisiensi operasional atau hambatan waktu kerja di lini produksi.

Ketiga, variabel *manpower_aktual* menunjukkan kontribusi paling rendah dengan skor di bawah 0,05. Temuan ini konsisten dengan hasil matriks korelasi sebelumnya yang menunjukkan hubungan linear yang lemah. Dalam konteks data ini, *manpower* terdeteksi hanya berfungsi sebagai kapasitas dasar (*baseline capacity*), bukan sebagai pemicu utama naik-turunnya output produksi harian. Artinya, kebijakan manajerial berupa penambahan tenaga kerja tidak akan meningkatkan output secara signifikan kecuali diimbangi dengan strategi penurunan SMV melalui perbaikan metode kerja atau peningkatan efisiensi untuk memperkecil *gap* SMV.

Temuan ini mengonfirmasi sekaligus memperluas hasil studi sebelumnya [5] mengenai pentingnya variabel SMV dalam perencanaan produksi. Sebagai kebaruan (*novelty*), penelitian ini membuktikan secara kuantitatif bahwa menekan inefisiensi waktu (*gap* SMV) di lapangan

memberikan dampak yang jauh lebih signifikan terhadap pencapaian target dibandingkan sekadar menambah jumlah tenaga kerja.

Selain itu, pemanfaatan algoritma *Machine Learning* dalam studi ini sejalan dengan paradigma Industri 4.0 [17]. Pendekatan tersebut terbukti lebih unggul dalam mengurai kompleksitas dan anomali data manufaktur dibandingkan metode analitik konvensional, sehingga mampu menghasilkan rekomendasi strategis yang lebih presisi bagi manajemen operasional.

5 Kesimpulan dan Saran

5.1 Kesimpulan

Penelitian ini menyimpulkan bahwa algoritma *Random Forest* terbukti memiliki kinerja prediktif yang lebih unggul dan stabil dibandingkan *Gradient Boosting* dalam memodelkan output produksi garmen. Hal ini ditunjukkan oleh nilai *error* yang lebih rendah (MAE 4,55; RMSE 6,85; MAPE 19,12%) dan nilai koefisien determinasi yang lebih tinggi ($R^2 = 0,758$). Selain itu, pengujian *5-Fold Cross Validation* menunjukkan bahwa *Random Forest* memiliki variabilitas yang lebih kecil (Standar Deviasi 0,1800), menjadikannya model yang lebih andal untuk menghadapi fluktuasi data di lantai produksi. Analisis *feature importance* mengungkapkan bahwa variabel SMV aktual merupakan determinan utama dalam menentukan output produksi (skor $>0,70$), disusul oleh *gap* SMV ($>0,20$). Temuan ini memberikan bukti empiris yang mematahkan asumsi konvensional bahwa penambahan tenaga kerja (*manpower*) adalah cara paling efektif untuk meningkatkan output. Data menunjukkan bahwa kontribusi *manpower* sangat rendah ($<0,05$), yang berarti peningkatan kapasitas produksi lebih bergantung pada optimalisasi metode kerja dan pengendalian *gap* SMV daripada sekadar kuantitas *manpower*.

5.2 Keterbatasan Penelitian dan Saran

Penelitian ini terbatas pada penggunaan data historis dan variabel teknis (SMV dan *manpower*) tanpa melibatkan faktor dinamis seperti absensi, kerusakan mesin, dan variasi material. Riset selanjutnya disarankan untuk melakukan validasi menggunakan data produksi terkini (*unseen data*) serta mengintegrasikan variabel operasional tambahan guna meningkatkan akurasi model. Selain itu, perbandingan antara estimasi *machine learning* dengan target konvensional perusahaan sangat diperlukan untuk membuktikan keandalan model dalam menghasilkan target produksi yang lebih realistis dan konsisten dibandingkan metode manual.

Referensi

- [1] T. Martina, I. Fauzi, U. Pramesvari, A. Ramadhan, and L. N. Asri, "Perancangan *Order Management System* berbasis *Web Application* untuk IKM Garmen," *Journal of Community Services in Sustainability*, Vol. 2, No. 1, pp. 1–10, 2024.
- [2] I. T. Kartika and N. Azizah, "Peran Industri Garmen sebagai Motor Pemberdayaan Perempuan di Bangladesh: Analisis Indikator," *Jurnal Hubungan Internasional*, Vol. 2, No. 1, pp. 261–281, Mar. 2025.
- [3] A. Anugrah, H. H. Mohamad, J. Otniel, M. R. Fahrezi, M. Radian, and F. Siswajanthi, "Analisis Industri Tekstil di Jawa Barat sebelum dan setelah Krisis Ekonomi," *Doktrin: Jurnal Dunia Ilmu Hukum dan Politik*, Vol. 2, No. 2, pp. 118–135, Apr. 2024.
- [4] P. K. Dewa, R. Meilina, S. Budiman, and I. N. Afiah, "Optimasi Capaian Target Produksi melalui Peningkatan Faktor Manusia," *Jurnal Penelitian dan Aplikasi Sistem dan Teknik Industri*, Vol. 18, No. 1, pp. 43–52, Apr. 2024.
- [5] S. A. Atsilia and D. Isfianadewi, "Implementation of Standard Minute Value (SMV) to Achieve Bra Production Target at PT Globalindo Intimates," *Jurnal Indonesia Sosial Teknologi*, Vol. 6, No. 1, pp. 649–665, Jan. 2025.
- [6] D. Yusuf and H. D. Ariessanti, "Pendekatan *Backpropagation* untuk Prediksi Penjualan Pakaian Jadi pada Pabrik Garmen di Tangerang," *JUSITI (Jurnal Sistem Informasi dan Teknologi Informasi)*, Vol. 14, No. 1, pp. 37–45, May 2025.
- [7] B. Bizuneh and R. Omer, "Lean Waste Prioritisation and Reduction in the Apparel Industry: Application of Waste Assessment Model and Value Stream Mapping," *Cogent Eng.*, Vol. 11, No. 1, pp. 1–22, Apr. 2024.

- [8] Kamruzzaman, T. A. T. Tutul, I. Hasan, A.-A. Prodhan, K. A. Tahmid, and A. Taher, "An Analysis of Standard Minute Value (SMV) to Increase Productivity in the Sewing Division: A Case Study on Jeans Pant Production," *International Conference on Mechanical, Industrial and Materials Engineering*, pp. 1–6, Dec. 2024.
- [9] M. Ewnetu and Y. Gzate, "Assembly Operation Productivity Improvement for Garment Production Industry Through the Integration of Lean and Work-Study, a Case Study on Bahir Dar Textile Share Company in Garment, Bahir Dar, Ethiopia," *Heliyon*, Vol. 9, pp. 1–13, Jul. 2023.
- [10] K. Antosz, L. Knapčíková, and J. Husár, "Evaluation and Application of Machine Learning Techniques for Quality Improvement in Metal Product Manufacturing," *Applied Sciences (Switzerland)*, Vol. 14, No. 10450, pp. 1–26, Nov. 2024.
- [11] Y. A. Purmala, "Penerapan *Machine Learning* dalam meningkatkan Produktivitas di Industri Manufaktur: Tinjauan Literatur," *Operations Excellence: Journal of Applied Industrial Engineering*, Vol. 13, No. 2, pp. 267–275, Jul. 2021.
- [12] F. H. Amrulloh, G. F. P. Aji, R. G. S, V. S. A. Anindyajati, R. N. Luthfi, and H. Tantyoko, "Klasifikasi Produktivitas Pekerja Garmen menggunakan *Algoritma Random Forest*," *Jurnal Buffer Informatika*, Vol. 10, No. 1, pp. 29–37, Apr. 2024.
- [13] A. N. A. Yusuf, Z. Z. Alkaf, E. S. H. Nurdiniyah, T. Wisudawati, and M. I. Fawzi, "Classification of Worker Productivity and Resource Allocation Optimization with Machine Learning: Garment Industry," *Jurnal Teknik Informatika (Jutif)*, Vol. 6, No. 5, pp. 2991–3001, Oct. 2025.
- [14] P. Chaporkar and R. Pandit, "Productivity Improvements in Manufacturing Industries using Machine Learning Algorithm," *J. Neonatal Surg.*, Vol. 14, No. 18s, pp. 127–137, 2025.
- [15] H. Tercan and T. Meisen, "Machine Learning and Deep Learning based Predictive Quality in Manufacturing: A Systematic Review," *J. Intell. Manuf.*, Vol. 33, pp. 1879–1905, May 2022.
- [16] I. Ayu, A. Fudoli, and M. H. Fahamsyah, "Metode Demand Forecasting dalam menjalankan Manajemen Operasi pada Industri Manufaktur," *EKOMABIS: Jurnal Ekonomi Manajemen Bisnis*, Vol. 3, No. 2, pp. 127–136, Aug. 2023.
- [17] H.-Y. Chen and C. Chen, "Review of Applications of Regression and Predictive Modeling in Wafer Manufacturing," *Electronics (Basel)*, Vol. 14, No. 4083, pp. 1–36, Oct. 2025.
- [18] T. Abedin, H. Xu, and S. Uddin, "The Impact of K Selection in K-Fold Cross-Validation on Bias and Variance in Supervised Learning Models," *SCI. Rep.*, Vol. 16, No. 6084, 2026.
- [19] D. N. Handayani and S. Qutub, "Penerapan *Random Forest* untuk Prediksi dan Analisis Kemiskinan," *RIGGS: Journal of Artificial Intelligence and Digital Business*, Vol. 4, No. 2, pp. 405–412, May 2025.
- [20] J. Gram, B. K. Sai, and T. Bauernhansl, "Root Cause Analysis of Productivity Losses in Manufacturing Systems Utilizing Ensemble Machine Learning," *Conference on Production Systems and Logistics*, pp. 368–379, 2024.
- [21] M. Miftakhudin, A. A. Murtopo, and Z. Arif, "Integrasi *Artificial Neural Network* dan Algoritma Genetika untuk Prediksi Bencana Banjir Pesisir Kota Tegal," *Journal of Artificial Intelligence and Digital Business*, Vol. 4, No. 3, pp. 840–848, Aug. 2025.
- [22] H. Kaneko, "Interpretation of Machine Learning Models for Data Sets with Many Features using Feature Importance," *American Chemical Society*, Vol. 8, pp. 23218–23225, Jun. 2023.