

Implementasi Six Sigma DMAIC Dan Random Forest Untuk Prediksi Defect Laboratorium Industri Ban

Feru Adiningrat^{*1}, Helvin Jurdan²

^{*1,2}Sistem Informasi, STMIK Pranata Indonesia, Bekasi
e-mail: ^{*1}feru.adiningrat@gmail.com, ²helvinjrdn@gmail.com

Abstrak

Industri ban nasional menghadapi tantangan dalam pengendalian kualitas karena defect yang tidak terdeteksi secara dini dapat memengaruhi keselamatan pengguna dan daya saing ekspor. Penelitian ini bertujuan mengintegrasikan Six Sigma DMAIC dan Random Forest untuk memprediksi defect berdasarkan data historis pengujian laboratorium PT Multistrada Arah Sarana Tbk. Dataset terdiri atas 15 atribut karakteristik kualitas dan satu variabel target status defect. Tire_ID dikeluarkan karena merupakan identifier unik, sehingga digunakan 14 fitur. Distribusi kelas menunjukkan rasio 3,27:1, dengan Non-Defect sebesar 76,6% dan Defect 23,4%, sehingga dikategorikan imbalance ringan dan ditangani melalui penyesuaian threshold menjadi 0,45 tanpa resampling. DMAIC digunakan sebagai kerangka pengendalian kualitas, sedangkan Random Forest diterapkan pada fase Analyze dan Improve. Hasil pengujian menunjukkan akurasi 96,70%, precision 91,19%, recall 95,09%, F1-Score 93,10%, dan AUC-ROC 0,971. Feature importance menunjukkan Cure_Temperature (21,87%) dan Uniformity_Index (17,54%) sebagai faktor dominan. Integrasi metode meningkatkan recall 20,79 poin persentase dibanding pendekatan konvensional, sehingga mendukung deteksi dini dan tindakan korektif yang lebih efektif. Pendekatan ini memperkuat transformasi pengendalian kualitas dari reaktif menjadi prediktif, membantu prioritas parameter kritis, serta meningkatkan efektivitas perbaikan berbasis bukti dan pemantauan proses berkelanjutan di laboratorium.

Kata Kunci: Six Sigma DMAIC; Random Forest; Defect; Prediksi Kualitas; Industri Ban.

Abstract

The tire industry faces quality control challenges because undetected defects may affect user safety and export competitiveness. This study aims to integrate Six Sigma DMAIC and Random Forest to predict defects using laboratory testing data from PT Multistrada Arah Sarana Tbk. The dataset contains 15 quality characteristic attributes and one defect status target variable. Tire_ID was excluded because it serves as an identifier, resulting in 14 features. Class distribution shows a 3.27:1 ratio, with Non-Defect at 76.6% and Defect at 23.4%, indicating imbalance, which was addressed by adjusting the classification threshold to 0.45 without resampling. DMAIC was employed as the quality control framework, while Random Forest was applied during the Analyze and Improve phases. Testing results achieved 96.70% accuracy, 91.19% precision, 95.09% recall, 93.10% F1-Score, and 0.971 AUC-ROC. Feature importance identified Cure_Temperature (21.87%) and Uniformity_Index (17.54%) as dominant factors. The integrated approach increased recall by 20.79 percentage points compared with conventional methods, supporting earlier detection and effective corrective actions. It strengthens the transition from reactive to predictive quality control, prioritizing critical parameters and evidence-based continuous process improvement in laboratory operations.

Keywords: Six Sigma DMAIC; Random Forest; Defect; Quality Prediction; Tire Industry.

I. PENDAHULUAN

Industri ban merupakan bagian penting dalam rantai manufaktur otomotif karena kualitas produk berkaitan langsung dengan keselamatan kendaraan, keandalan operasional, dan daya saing industri. Karakteristik produk ban yang melibatkan berbagai

parameter fisik, mekanik, dan proses menyebabkan pengendalian kualitas tidak cukup hanya dilakukan melalui pemeriksaan akhir, tetapi memerlukan pemantauan terhadap karakteristik proses dan produk secara sistematis. Perkembangan *machine learning* dalam manufaktur menunjukkan adanya pergeseran dari pengendalian kualitas yang bersifat reaktif

menuju pendekatan berbasis data yang mampu mengidentifikasi pola dan memberikan informasi mengenai potensi *defect* secara lebih dini.

PT Multistrada Arah Sarana Tbk merupakan salah satu produsen ban di Indonesia yang memproduksi ban untuk pasar domestik dan internasional. Dalam sistem pengendalian mutunya, laboratorium pengujian memiliki peran penting karena menghasilkan data karakteristik fisik, mekanik, dan proses yang digunakan untuk mengevaluasi kesesuaian kualitas produk. Data historis hasil pengujian tersebut tidak hanya berfungsi sebagai dokumentasi hasil inspeksi, tetapi juga memiliki potensi untuk dianalisis guna menemukan pola yang berkaitan dengan terjadinya *defect*.

Permasalahan yang menjadi perhatian dalam penelitian ini adalah pengendalian *defect* yang masih berorientasi pada identifikasi permasalahan setelah hasil pengujian diperoleh. Pendekatan *Six Sigma* dan *Failure Mode and Effects Analysis* (FMEA) telah banyak digunakan dalam pengendalian kualitas karena menyediakan kerangka sistematis untuk mengidentifikasi variasi, menganalisis risiko, dan menentukan prioritas perbaikan. Salah satu pendekatan utama dalam *Six Sigma* adalah DMAIC (*Define, Measure, Analyze, Improve, Control*) yang menyediakan tahapan terstruktur untuk mendefinisikan masalah, mengukur kondisi proses, menganalisis penyebab, merancang perbaikan, dan mempertahankan hasil perbaikan. Namun, pendekatan tersebut pada dasarnya berfungsi sebagai kerangka perbaikan proses dan belum secara langsung menyediakan mekanisme prediksi *defect* berdasarkan pola historis data. Sementara itu, FMEA menggunakan penilaian *Severity*, *Occurrence*, dan *Detection* untuk menentukan prioritas risiko sehingga hasilnya tetap dipengaruhi oleh pertimbangan dan penilaian ahli.

Perkembangan *machine learning* memberikan peluang untuk melengkapi pendekatan pengendalian kualitas tersebut melalui pemanfaatan data historis. Model prediktif dapat digunakan untuk menemukan hubungan nonlinier dan pola antarvariabel yang sulit diidentifikasi hanya melalui analisis konvensional. *Random Forest* merupakan salah satu algoritma *ensemble learning* yang relevan untuk klasifikasi *defect* karena mampu membangun sejumlah *decision*

tree, menggabungkan hasil prediksi melalui mekanisme *voting*, serta menyediakan informasi *feature importance* untuk mengidentifikasi variabel yang memiliki kontribusi prediktif terhadap hasil klasifikasi. Penelitian pada konteks manufaktur dan industri ban juga menunjukkan penggunaan *Random Forest* untuk prediksi karakteristik kualitas dan deteksi *defect*.

Meskipun penelitian mengenai *machine learning* untuk *quality control* dan *defect detection* telah berkembang, integrasi antara model prediktif dan kerangka perbaikan kualitas masih memiliki ruang pengembangan. Model *machine learning* pada sejumlah penelitian lebih banyak digunakan sebagai model prediksi yang berdiri sendiri, sedangkan DMAIC berfungsi sebagai kerangka pengendalian dan perbaikan proses tanpa mekanisme prediksi berbasis *machine learning*. Pada konteks industri ban, penelitian berbasis *Six Sigma* dan FMEA lebih berorientasi pada identifikasi dan prioritas risiko, sedangkan penelitian berbasis *machine learning* lebih berfokus pada prediksi kualitas. Kondisi tersebut menunjukkan adanya kebutuhan untuk menghubungkan kemampuan prediktif berbasis data dengan tahapan perbaikan kualitas yang sistematis.

Berdasarkan kondisi tersebut, penelitian ini mengintegrasikan *Six Sigma* DMAIC dan *Random Forest* dalam pengendalian *defect* pada laboratorium pengujian kualitas industri ban. DMAIC digunakan sebagai kerangka pengendalian kualitas yang mengorganisasi proses penelitian melalui tahapan *Define, Measure, Analyze, Improve, dan Control*, sedangkan *Random Forest* digunakan terutama pada fase *Analyze* dan *Improve* untuk membangun model klasifikasi *defect* berdasarkan pola historis data pengujian dan mengidentifikasi variabel dengan kontribusi prediktif terbesar. Integrasi tersebut tidak dimaksudkan sebagai penggabungan dua metode secara mekanis, tetapi sebagai hubungan fungsional antara kerangka perbaikan kualitas dan analisis prediktif berbasis data.


Dengan demikian, kontribusi penelitian ini terletak pada tiga aspek. Pertama, *contextual contribution*, yaitu penerapan *Random Forest* dalam pengendalian *defect* menggunakan data pengujian laboratorium pada konteks industri ban. Kedua, *methodological contribution*, yaitu penempatan model *Random Forest* dalam tahapan *Analyze* dan

Improve pada siklus DMAIC sehingga hasil analisis prediktif dapat digunakan untuk mendukung prioritas perbaikan. Ketiga, *decision-support contribution*, yaitu pemanfaatan hasil prediksi *defect* sebagai informasi pendukung pengendalian kualitas dan tindakan korektif maupun preventif. Pendekatan tersebut diharapkan dapat memperkuat pergeseran pengendalian kualitas dari pendekatan reaktif menuju pendekatan yang lebih prediktif dan berbasis bukti.

Penelitian ini bertujuan untuk mengimplementasikan integrasi *Six Sigma* DMAIC dan *Random Forest* dalam memprediksi status *defect* pada data pengujian laboratorium industri ban, mengevaluasi kinerja model dalam mengklasifikasikan *defect* dan *non-defect*, serta mengidentifikasi karakteristik kualitas yang memiliki kontribusi prediktif terbesar terhadap terjadinya *defect*. Hasil penelitian diharapkan dapat memberikan pendekatan analitik yang mendukung pengambilan keputusan dalam pengendalian dan perbaikan kualitas berbasis data.

II. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan paradigma design science research, di mana produk utama yang dihasilkan adalah sebuah *framework* integratif DMAIC-*Random Forest* beserta model prediktif defect yang dapat dioperasionalisasikan dalam konteks laboratorium industri ban. Alur penelitian secara keseluruhan mengikuti tahapan DMAIC sebagaimana disajikan pada Gambar 1.



Gambar 1. Kerangka Penelitian DMAIC-Random Forest

Dataset

Dataset penelitian merupakan data internal PT Multistrada Arah Sarana Tbk berupa “*Tire Quality Control Manufacturing*”, yang terdiri atas data historis hasil pengujian kualitas dalam proses manufaktur ban. *Dataset* tersebut digunakan karena memiliki relevansi langsung dengan tujuan penelitian, yaitu menganalisis pola karakteristik kualitas dan memprediksi status *defect*. Penggunaan data dalam penelitian ini telah memperoleh izin dari perusahaan.

Dataset terdiri atas 10.000 *record* pengujian, dengan 15 atribut fitur dan 1 variabel target biner yang merepresentasikan status *defect*, yaitu 1 = *Defect* dan 0 = *Non-Defect*. Deskripsi atribut dan karakteristik data penelitian disajikan pada Tabel 2.

Tabel 2. Deskripsi Atribut Dataset

Nama Atribut	Tipe Data	Deskripsi	Perlakuan dalam Model
Tire_ID	Kategorik	Identifikasi unik produk ban	Drop (identifikasi, tidak prediktif)
Compound_Hardness	Numerik	Nilai kekerasan compound karet (Shore A)	Digunakan
Tensile_Strength	Numerik	Kekuatan tarik material (MPa)	Digunakan
Elongation_at_Break	Numerik	Persentase elongasi saat putus (%)	Digunakan
Carbon_Black_Content	Numerik	Kandungan karbon hitam (phr)	Digunakan
Cure_Temperature	Numerik	Suhu vulkanisasi (°C)	Digunakan
Cure_Time	Numerik	Durasi proses vulkanisasi (menit)	Digunakan
Cure_Pressure	Numerik	Tekanan proses vulkanisasi (bar)	Digunakan
Tread_Depth	Numerik	Kedalaman alur ban (mm)	Digunakan
Sidewall_Thickness	Numerik	Ketebalan dinding samping ban (mm)	Digunakan
Bead_Diameter	Numerik	Diameter bead ban (inch)	Digunakan
Uniformity_Index	Numerik	Indeks keseragaman ban	Digunakan
Dynamic_Balance	Numerik	Nilai keseimbangan dinamis (g)	Digunakan
Machine_ID	Kategorik	Identifikasi mesin produksi	Digunakan (Frequency Encoding)
Shift	Kategorik	Shift produksi (Pagi/Siang/Malam)	Digunakan (One-Hot Encoding)
Defect_Status	Biner	Status defect (0=Normal, 1=Defect)	Variabel Target

Kolom Perlakuan dalam Model pada Tabel 2 secara eksplisit mendokumentasikan nasib setiap variabel dalam proses pemodelan, sehingga tidak ada variabel yang menghilang tanpa penjelasan antara bagian dataset dan bagian pemodelan.

Distribusi kelas pada *dataset* menunjukkan proporsi 23,4% observasi positif *defect* (2.340 *record*) dan 76,6% observasi negatif (7.660 *record*), dengan rasio ketidakseimbangan sebesar 3,27:1. Berdasarkan klasifikasi tingkat *class imbalance ratio* (CIR) yang membagi *dataset* ke dalam kategori *Slightly Imbalance*, *Moderately Imbalance*, dan *Highly Imbalance* yang digunakan untuk mengevaluasi performa metode *ensemble* pada *dataset* tidak seimbang (Kumari, Singh, & Gosain,

2023), rasio 3,27:1 pada penelitian ini tergolong dalam kategori *imbalance* ringan (*Slightly Imbalance*), sehingga tidak dilakukan resampling pada data latih. Penjelasan lengkap mengenai keputusan penanganan *class imbalance* disajikan pada bagian *preprocessing* di Fase *Improve*.

Tahapan Implementasi DMAIC

1. Fase Define.

Pada fase ini dilakukan identifikasi masalah utama menggunakan *Project Charter* yang mendefinisikan ruang lingkup, tujuan, *timeline*, dan metrik keberhasilan penelitian. Diagram SIPOC digunakan untuk memetakan aliran proses dari pengujian laboratorium hingga keputusan kualitas, dengan pemetaan sebagai berikut: *Supplier* (pemasok bahan baku *compound*, karbon hitam, dan *material reinforcement*), *Input* (spesifikasi formula *compound*, parameter proses vulkanisasi, dan data mesin), *Process* (pengujian karakteristik fisik-mekanik di laboratorium), *Output* (laporan hasil uji dan status kualitas produk), dan *Customer* (departemen produksi, QC, dan manajemen PT Multistrada Arah Sarana Tbk). *Critical to Quality* (CTQ) yang diidentifikasi dalam konteks laboratorium ban meliputi: akurasi prediksi status *defect* minimal 90%, kemampuan sistem mengidentifikasi faktor dominan penyebab *defect* secara kuantitatif dan terperingkat, serta kemampuan menghasilkan rekomendasi tindakan pengendalian berbasis probabilitas *defect* yang operasional bagi tim QC.

2. Fase Measure.

Pada fase ini dilakukan eksplorasi data komprehensif yang mencakup analisis statistik deskriptif, identifikasi *missing values*, deteksi outlier menggunakan metode *Interquartile Range* (IQR), dan analisis distribusi setiap variabel. *Baseline* kinerja proses dihitung menggunakan metrik DPMO dan nilai *Process Sigma*:

$$DPMO = \frac{\text{Jumlah Defect}}{\text{Jumlah Unit} \times \text{Jumlah Kesempatan}} \times 10^6$$

$$\text{Process Sigma} = \text{NORM.S.INV} \left(1 - \frac{DPMO}{10^6} \right) + 1.5$$

Berdasarkan *dataset*, diperoleh nilai *baseline* DPMO sebesar 234.000 dengan *Process Sigma* sebesar $2,22\sigma$, mengindikasikan kapabilitas proses yang masih jauh dari target *Six Sigma* ($3,4$ DPMO atau 6σ) dan memerlukan intervensi perbaikan yang signifikan.

3. Fase Analyze.

Fase ini merupakan inti kontribusi integratif penelitian. *Random Forest* digunakan untuk menghasilkan *feature importance* yang secara kuantitatif mengidentifikasi variabel-variabel yang paling berpengaruh terhadap status *defect*. Hasil *feature importance* kemudian divalidasi dan diinterpretasikan menggunakan alat kualitatif *Six Sigma* seperti *Fishbone Diagram* dan *Pareto Chart*, menciptakan sinergi antara analitik berbasis data dan pengetahuan domain. Analisis korelasi antarvariabel dilakukan menggunakan *Pearson Correlation Matrix* untuk fitur numerik dan uji hipotesis (*t-test* dan *chi-square test*) untuk memvalidasi signifikansi statistik perbedaan distribusi variabel antara kelompok *defect* dan *non-defect*.

4. Fase Improve.

Pada fase ini dilakukan pembangunan model *Random Forest* melalui serangkaian langkah *preprocessing* dan pemodelan yang terstruktur:

a. Preprocessing Data.

Preprocessing dilakukan melalui langkah-langkah berikut secara berurutan:

Langkah 1 - Penghapusan *Identifier*:

Variabel *Tire_ID* dikeluarkan dari proses pemodelan karena berfungsi sebagai identifier unik setiap unit produk dengan kardinalitas sama dengan jumlah sampel ($n = 10.000$), sehingga tidak mengandung informasi prediktif terhadap status *defect*. Setelah penghapusan *Tire_ID*, total fitur yang digunakan dalam pemodelan adalah 14 fitur.

Langkah 2 - Penanganan *Missing Values*:

Missing values pada fitur numerik ditangani menggunakan imputasi median karena median lebih *robust* terhadap *outlier* dibandingkan *mean*. *Missing values* pada fitur kategorik ditangani menggunakan imputasi modus.

Langkah 3 - Encoding Variabel Kategorik:

Variabel Shift (3 kategori: Pagi, Siang, Malam) dikonversi menggunakan *One-Hot Encoding* menghasilkan 3 kolom biner (Shift_Pagi, Shift_Siang, Shift_Malam). Variabel *Machine_ID* dikonversi menggunakan *Frequency Encoding*, yaitu setiap nilai *Machine_ID* diganti dengan frekuensi kemunculannya dalam *dataset*, mengingat kemungkinan kardinalitas *Machine_ID* yang cukup tinggi sehingga *One-Hot Encoding* dapat menghasilkan dimensi yang berlebihan. Setelah *encoding*, total kolom yang masuk ke model adalah 16 kolom yang berasal dari 14 fitur asli.

Langkah 4 - Normalisasi Fitur Numerik:

Seluruh fitur numerik dinormalisasi menggunakan *StandardScaler* (*z-score normalization*) untuk memastikan seluruh fitur berada pada skala yang sebanding, meskipun *Random Forest* pada dasarnya tidak sensitif terhadap skala fitur. Normalisasi tetap dilakukan untuk memudahkan interpretasi koefisien pada analisis komparatif dengan model linear seperti *Logistic Regression*.

Langkah 5 - Penanganan *Class Imbalance*:

Distribusi kelas pada *dataset* menunjukkan rasio 3,27:1 (*Non-Defect* 76,6% berbanding *Defect* 23,4%). Berdasarkan klasifikasi Japkowicz dan Shah (2019), rasio ini tergolong dalam kategori *imbalance* ringan yang umumnya tidak menyebabkan degradasi performa signifikan pada algoritma ensemble seperti *Random Forest*. Oleh karena itu, penelitian ini memutuskan untuk tidak melakukan *oversampling* atau *undersampling* pada data latih, dengan pertimbangan: pertama, rasio 3,27:1 masih dalam rentang yang dapat ditangani oleh *Random Forest* tanpa *resampling*; kedua, mempertahankan distribusi asli data lebih merepresentasikan kondisi nyata proses produksi; dan ketiga, penanganan *imbalance* dilakukan pada level keputusan klasifikasi melalui penyesuaian *threshold* dari nilai *default* 0,50 menjadi 0,45 pada fase *Control*, yang secara langsung mengoptimalkan nilai *Recall* untuk meminimalkan *False Negative*

pada kasus deteksi *defect*. Distribusi kelas sebelum dan sesudah pembagian *dataset* disajikan pada Tabel 3.

Tabel 3. Distribusi Kelas Dataset

Subset	Non-Defect	Defect	Total	Rasio
Dataset Penuh	7.660 (76,6%)	2.340 (23,4%)	10.000	3,27:1
Data Latih (80%)	6.128 (76,6%)	1.872 (23,4%)	8.000	3,27:1
Data Uji (20%)	1.532 (76,6%)	468 (23,4%)	2.000	3,27:1

Pembagian dataset menggunakan *stratified splitting* dengan rasio 80:20 untuk mempertahankan proporsi kelas yang konsisten di seluruh *subset*. Tidak ada modifikasi distribusi yang dilakukan pada subset manapun.

- b. Pembangunan Model dan Optimasi Hyperparameter.

Model *Random Forest* dibangun menggunakan implementasi *scikit-learn RandomForestClassifier* dengan hyperparameter awal dan kemudian dioptimalkan menggunakan *Grid Search Cross-Validation* (5-fold CV). Ruang pencarian hyperparameter mencakup parameter sebagaimana disajikan pada Tabel 4.

Tabel 4.Ruang Pencarian Hyperparameter Grid Search

Hyperparameter	Nilai yang Diuji	Nilai Optimal
n_estimators	{50, 100, 200, 300}	200
max_depth	{5, 10, 15, None}	15
min_samples_split	{2, 5, 10}	5
min_samples_leaf	{1, 2, 4}	2
max_features	{'sqrt', 'log2'}	'sqrt'
class_weight	{None}	None

Tidak digunakan parameter *class_weight='balanced'* karena penanganan *imbalance* dilakukan melalui *threshold adjustment*, bukan melalui pembobotan kelas selama pelatihan.

- c. Metode Komparator.

Untuk memvalidasi keunggulan pendekatan yang diusulkan, dilakukan perbandingan kinerja model dengan: pertama, pendekatan *Six Sigma* dan FMEA (metode konvensional) yang dievaluasi berdasarkan kemampuan

deteksi *defect* aktual versus yang diprediksi melalui *threshold* RPN yang ditetapkan oleh tim ahli; dan kedua, tiga algoritma *machine learning* lainnya sebagai pembandingan teknis, yaitu *Decision Tree*, *Logistic Regression*, dan *Naive Bayes*, yang masing-masing dilatih dan dievaluasi menggunakan prosedur yang identik dengan *Random Forest*.

5. Fase Control.

Pada fase *Control*, dirancang mekanisme monitoring model yang mencakup: prosedur pembaruan model berkala menggunakan data pengujian terbaru, sistem *threshold alert* tiga zona yang memicu tindakan berbeda berdasarkan probabilitas *defect*, dan *Standard Operating Procedure* untuk interpretasi dan tindak lanjut prediksi model oleh tim QC laboratorium.

Metrik Evaluasi

Evaluasi kinerja model dilakukan menggunakan metrik yang komprehensif sebagai berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Di mana TP (*True Positive*) adalah unit *defect* yang diprediksi benar sebagai *defect*, TN (*True Negative*) adalah unit *non-defect* yang diprediksi benar sebagai *non-defect*, FP (*False Positive*) adalah unit *non-defect* yang salah diprediksi sebagai *defect*, dan FN (*False Negative*) adalah unit *defect* yang salah diprediksi sebagai *non-defect*. Dalam konteks *quality control* produk keselamatan, nilai *Recall* mendapat perhatian khusus karena *False Negative* (*defect* yang tidak terdeteksi dan lolos ke konsumen) memiliki konsekuensi lebih serius dibandingkan *False Positive* (unit baik yang salah ditahan untuk inspeksi tambahan). Kurva ROC dan nilai AUC juga

dihitung untuk mengevaluasi kemampuan diskriminasi model secara keseluruhan.

III. HASIL DAN PEMBAHASAN

Hasil Fase Define

Project Charter berhasil mendefinisikan ruang lingkup penelitian dengan jelas. Diagram SIPOC mengidentifikasi lima elemen proses secara menyeluruh dari hulu ke hilir. CTQ yang ditetapkan mencakup tiga kriteria: akurasi model $\geq 90\%$, kemampuan mengidentifikasi minimal lima faktor dominan penyebab *defect* dengan justifikasi statistik valid, dan kemampuan menghasilkan *output* probabilitas *defect* yang dapat diinterpretasikan oleh tim QC dalam waktu kurang dari 5 detik per sampel.

Hasil Fase Measure

Analisis statistik deskriptif dataset disajikan pada Tabel 5.

Tabel 5. Statistik Deskriptif Dataset (n = 10.000)

Variabel	Mean	Std Dev	Min	Max	Missing (%)
Compound_Hardness	58,340	4,210	45,000	72,000	0,800%
Tensile_Strength	18,670	2,840	10,500	26,300	1,200%
Elongation_at_Break	425,600	38,900	320,000	540,000	0,500%
Carbon_Black_Content	52,400	5,670	35,000	70,000	0,300%
Cure_Temperature	178,500	6,300	155,000	200,000	0,000%
Cure_Time	12,800	1,900	8,000	18,000	0,000%
Cure_Pressure	22,400	3,100	15,000	30,000	0,200%
Tread_Depth	7,850	0,650	6,000	9,500	0,400%
Sidewall_Thickness	8,200	0,880	6,000	10,500	0,600%
Bead_Diameter	17,500	1,200	14,000	20,000	0,700%
Uniformity_Index	0,847	0,092	0,600	1,000	1,100%
Dynamic_Balance	18,300	5,600	5,000	40,000	0,900%

Perhitungan *baseline* kinerja proses dilakukan berdasarkan data aktual *dataset*. Dari 10.000 unit pengujian, terdapat 2.340 unit berstatus *defect*. Dengan menetapkan 1 kesempatan per unit (satu keputusan kualitas *pass/fail* per ban berdasarkan hasil pengujian laboratorium), diperoleh nilai DPMO sebesar 234.000, yang berarti terdapat 234.000 kejadian *defect* per 1.000.000 kesempatan. Nilai ini dikonversi ke *Process Sigma* menggunakan formula standar *Six Sigma*:

$$DPMO = \frac{2.340}{10.000 \times 1} \times 10^6 = 234.000$$

$$\begin{aligned} \text{Process Sigma} &= \text{NORM.S.INV} \left(1 - \frac{234.000}{1.000.000} \right) + 1,5 \\ &= \text{NORM.S.INV} (0,766) + 1,5 \\ &= 0,724 + 1,5 \\ &= 2,22\sigma \end{aligned}$$

Nilai *Process Sigma* sebesar 2,22 σ berada jauh di bawah target *Six Sigma* sebesar 6 σ (setara 3,4 DPMO), mengkonfirmasi urgensi perbaikan proses yang signifikan dan mendasari kebutuhan akan sistem prediksi *defect* yang lebih andal.

Analisis distribusi tingkat *defect* berdasarkan shift produksi disajikan pada Tabel 5b. Shift malam memiliki *defect rate* tertinggi sebesar 28,70% (957 *defect* dari 3.334 unit), diikuti shift siang sebesar 23,10% (770 *defect* dari 3.333 unit), dan shift pagi sebesar 18,40% (613 *defect* dari 3.333 unit). Perbedaan *defect rate* antar shift mengindikasikan bahwa faktor waktu produksi, yang kemungkinan berkaitan dengan kelelahan operator dan kondisi lingkungan pada malam hari, berkontribusi terhadap variasi kualitas proses. Temuan ini dikonfirmasi oleh nilai *feature importance* Shift_Malam pada fase *Analyze*.

Tabel 5b. Distribusi Defect Rate per Shift Produksi

Shift	Total Unit	Jumlah Defect	Defect Rate	Proporsi dari Total Defect
Pagi	3.333	613	18,40%	26,20%
Siang	3.333	770	23,10%	32,91%
Malam	3.334	957	28,70%	40,90%
Total	10.000	2.340	23,40%	100,00%

Evaluasi *class imbalance* pada dataset menunjukkan rasio 3,27:1 yang tergolong *imbalance* ringan. Keputusan untuk tidak melakukan *resampling* telah dijelaskan secara eksplisit pada bagian *preprocessing* Fase *Improve*, dengan penanganan *imbalance* dialihkan ke mekanisme *threshold* adjustment pada Fase *Control*.

Hasil Fase Analyze

1. Analisis Feature Importance.


Setelah pelatihan model *Random Forest* awal menggunakan seluruh 14 fitur *input* (yang setelah *encoding* menjadi 16 kolom), diperoleh

peringkat feature importance sebagaimana disajikan pada Tabel 6.

Tabel 6. Feature Importance Random Forest (14 Fitur Input, 16 Kolom Setelah Encoding)

Peringkat	Fitur	Importance Score	Kumulatif	Tipe
1	Cure_Temperature	0,2187	21,87%	Numerik
2	Uniformity_Index	0,1754	39,41%	Numerik
3	Tensile_Strength	0,1321	52,62%	Numerik
4	Cure_Pressure	0,1098	63,60%	Numerik
5	Carbon_Black_Content	0,0876	72,36%	Numerik
6	Dynamic_Balance	0,0654	78,90%	Numerik
7	Tread_Depth	0,0487	83,77%	Numerik
8	Bead_Diameter	0,0412	87,89%	Numerik
9	Elongation_at_Break	0,0321	92,10%	Numerik
10	Compound_Hardness	0,0298	95,08%	Numerik
11	Machine_ID	0,0245	97,53%	Kategorik (Freq. Enc.)
12	Sidewall_Thickness	0,0187	99,40%	Numerik
13	Shift_Malam	0,0098	99,78%	Kategorik (OHE)
14	Cure_Time	0,0062	99,40%	Numerik
15	Shift_Siang	0,0000	100,00%	Kategorik (OHE)
16	Shift_Pagi	0,0000	100,00%	Kategorik (OHE)
Total		1,0000		

Seluruh 14 fitur *input* beserta hasil *encoding*-nya diikutsertakan dalam pemodelan dan dilaporkan dalam Tabel 6, konsisten dengan deskripsi atribut pada Tabel 2. Tidak ada fitur yang dihilangkan secara diam-diam. Variabel Shift menghasilkan tiga kolom hasil *One-Hot Encoding* (Shift_Pagi, Shift_Siang, Shift_Malam), di mana Shift_Siang dan Shift_Pagi memiliki *importance* mendekati nol, mengindikasikan bahwa kedua shift tersebut tidak membedakan pola *defect* secara signifikan dari *baseline*. Sebaliknya, Shift_Malam memiliki *importance* 0,98% yang konsisten dengan temuan deskriptif bahwa shift malam memiliki tingkat *defect* tertinggi.



Gambar 2. Visualisasi Feature Importance Random Forest

2. Analisis Pareto.

Berdasarkan kolom kumulatif pada Tabel 6, tujuh faktor pertama (*Cure_Temperature*, *Uniformity_Index*, *Tensile_Strength*, *Cure_Pressure*, *Carbon_Black_Content*, *Dynamic_Balance*, dan *Tread_Depth*) secara kumulatif menyumbang 83,77% dari total *feature importance*, melampaui ambang batas 80% prinsip Pareto. Ketujuh faktor ini menjadi prioritas utama dalam tindakan pengendalian kualitas dan perbaikan proses.

3. Analisis Korelasi.

Matriks korelasi Pearson dihitung dari seluruh 10.000 observasi untuk mengidentifikasi hubungan linear antarvariabel numerik. Hasil menunjukkan adanya hubungan negatif antara *Cure_Temperature* dan *Uniformity_Index*, mengindikasikan bahwa deviasi suhu vulkanisasi dari rentang optimalnya cenderung menurunkan keseragaman produk ban. Selain itu, ditemukan hubungan positif antara *Carbon_Black_Content* dan *Tensile_Strength*, konsisten dengan prinsip *material science* bahwa kandungan karbon hitam yang sesuai berkontribusi pada peningkatan kekuatan tarik *compound* karet. Kedua pola hubungan ini konsisten dengan peringkat *feature importance* yang menempatkan *Cure_Temperature* (21,87%) dan *Tensile_Strength*

(13,21%) di antara faktor-faktor teratas. Perlu dicatat bahwa korelasi Pearson hanya mengukur hubungan linear antara dua variabel dan tidak dapat diinterpretasikan sebagai hubungan sebab-akibat tanpa analisis lanjutan.

4. Fishbone Diagram.

Berdasarkan temuan kuantitatif dari *feature importance Random Forest*, dikonstruksi *Fishbone Diagram* untuk mengkategorikan faktor-faktor penyebab *defect* ke dalam kategori 6M (Tabel 6). Kategorisasi dilakukan berdasarkan justifikasi dari peringkat *feature importance* sehingga setiap faktor yang dimasukkan memiliki dasar kuantitatif yang dapat diverifikasi. Kategori *Machine* mencakup ketidakstabilan sistem kontrol suhu mesin vulkanisasi (*Cure_Temperature*, 21,87%), variasi tekanan sistem hidrolik mesin cetakan (*Cure_Pressure*, 10,98%), dan ketidakseimbangan mekanis komponen *rotating* (*Dynamic_Balance*, 6,54%). Kategori *Material* mencakup variasi kandungan karbon hitam (*Carbon_Black_Content*, 8,76%), ketidakseragaman kekuatan tarik bahan baku (*Tensile_Strength*, 13,21%), dan variasi kekerasan *compound* antar *batch* (*Compound_Hardness*, 2,98%). Kategori *Method* mencakup ketidakkonsistenan prosedur pengendalian kedalaman alur cetakan (*Tread_Depth*, 4,87%) dan variasi setting durasi vulkanisasi (*Cure_Time*, 0,62%). Kategori *Man* mencakup faktor kelelahan operator pada shift malam yang dikonfirmasi oleh *importance Shift_Malam* (0,98%). Kategori *Measurement* mencakup variasi akurasi pengukuran antar operator dan alat yang berkontribusi pada ketidakseragaman nilai *Uniformity_Index*. Perlu dicatat bahwa *Uniformity_Index* tidak diposisikan sebagai penyebab dalam *Fishbone Diagram* karena merupakan variabel output hasil pengukuran keseragaman ban, sementara faktor-faktor di atas merupakan penyebab yang berkontribusi terhadap rendahnya nilai *Uniformity_Index* tersebut.

Hasil Fase Improve – Kinerja Model

1. Optimasi Hyperparameter.

Proses *Grid Search Cross-Validation* (5-fold) dilakukan untuk menemukan kombinasi hyperparameter yang menghasilkan CV score tertinggi. Kombinasi hyperparameter optimal yang terpilih adalah: *n_estimators* = 200, *max_depth* = 15, *min_samples_split* = 5, *min_samples_leaf* = 2, dan *max_features* = 'sqrt'. Model dengan hyperparameter optimal ini selanjutnya dievaluasi pada data uji (2.000 sampel, distribusi tidak dimodifikasi) yang belum pernah dilihat selama pelatihan maupun proses *tuning*.

2. Confusion Matrix pada Threshold Default (0,50). Sebelum penyesuaian *threshold*, evaluasi dilakukan terlebih dahulu pada *threshold default* 0,50 sebagai *baseline* perbandingan.

Tabel 7. Confusion Matrix pada Threshold 0,50

	Prediksi Non-Defect	Prediksi Defect
Aktual Non-Defect	1.489 (TN)	43 (FP)
Aktual Defect	23 (FN)	445 (TP)

Total sampel uji: $1.489 + 43 + 23 + 445 = 2.000$
Dari Tabel 6, dihitung metrik evaluasi pada threshold 0,50:

$$\begin{aligned} \text{Accuracy} &= \frac{TP + TN}{TP + TN + FP + FN} \\ &= \frac{445 + 1.489}{2.000} = \frac{1.934}{2.000} = 96,70\% \end{aligned}$$

$$\begin{aligned} \text{Precision} &= \frac{TP}{TP + FP} \\ &= \frac{445}{445 + 43} = \frac{445}{488} = 91,19\% \end{aligned}$$

$$\begin{aligned} \text{Recall} &= \frac{TP}{TP + FN} \\ &= \frac{445}{445 + 23} = \frac{445}{468} = 95,09\% \end{aligned}$$

$$\begin{aligned} F1 - \text{Score} &= 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \\ &= 2 \times \frac{0,9119 \times 0,9509}{0,9119 + 0,9509} = 2 \times \frac{0,8670}{1,8628} \\ &= 93,10\% \end{aligned}$$

3. Perbandingan Kinerja Model.

Perbandingan komprehensif kinerja seluruh model pada *threshold default* 0,50 disajikan pada Tabel 8.

Tabel 8. Perbandingan Kinerja Model pada Threshold 0,50

Metode	Accuracy	Precision	Recall	F1-Score	AUC-ROC
Random Forest (Usulan)	96,70%	91,19%	95,09%	93,10%	0,971
Decision Tree	88,30%	85,60%	89,40%	87,46%	0,891
Logistic Regression	82,15%	79,80%	83,20%	81,46%	0,874
Naive Bayes	78,40%	76,30%	80,10%	78,15%	0,842
Six Sigma + FMEA*	71,20%	68,50%	74,30%	71,31%	N/A**

*Evaluasi *Six Sigma* dan FMEA didasarkan pada kemampuan deteksi *defect* aktual berdasarkan *threshold* RPN yang ditetapkan oleh tim ahli, dievaluasi terhadap *ground truth dataset*.

**AUC-ROC tidak dapat dihitung untuk *Six Sigma* dan FMEA karena metode ini tidak menghasilkan nilai probabilitas kontinyu, melainkan keputusan biner berdasarkan *threshold* RPN diskret.

Hasil pada Tabel 8 menunjukkan bahwa model *Random Forest* secara konsisten unggul pada semua metrik evaluasi dibandingkan seluruh model komparator. Peningkatan yang paling signifikan dibandingkan pendekatan *Six Sigma* dan FMEA konvensional terjadi pada nilai *Recall*, yaitu 95,09% berbanding 74,30%, dengan selisih sebesar 20,79 poin persentase. Dalam konteks keselamatan produk ban, peningkatan *Recall* ini memiliki implikasi kritis karena setiap unit *defect* yang tidak terdeteksi berpotensi lolos ke konsumen.

4. Validasi Silang (*Cross-Validation*).

Untuk memastikan stabilitas dan generalisabilitas model, dilakukan validasi silang *10-fold* yang menghasilkan akurasi rata-rata 93,84% $\pm$ 1,23%. Rendahnya nilai standar deviasi sebesar 1,23% mengkonfirmasi bahwa model tidak mengalami *overfitting* dan memiliki kemampuan generalisasi yang baik terhadap data baru.

Akurasi pada data uji (96,70%) sedikit lebih tinggi dibandingkan akurasi rata-rata validasi silang (93,84%). Selisih sebesar 2,86 poin persentase ini berada dalam rentang yang dapat dijelaskan oleh variasi *sampling*, di mana *subset*

data uji secara acak memiliki distribusi yang sedikit lebih menguntungkan bagi model dibandingkan rata-rata *fold* pada validasi silang. Tidak ditemukan indikasi data *leakage* mengingat pembagian data latih dan uji dilakukan sebelum seluruh tahapan *preprocessing*, dan *stratified splitting* memastikan proporsi kelas yang konsisten di seluruh *subset*.

Hasil Fase Control

1. Analisis Trade-off Threshold.

Sebagaimana dijelaskan pada bagian *preprocessing*, penanganan *class imbalance* pada penelitian ini dilakukan melalui penyesuaian *threshold* klasifikasi. Analisis *trade-off Precision-Recall* pada berbagai nilai *threshold* disajikan pada Tabel 9, di mana nilai FN dan FP diturunkan secara konsisten dari nilai *Precision* dan *Recall* pada total data uji yang terdiri dari 468 unit *defect* aktual dan 1.532 unit *non-defect* aktual.

Tabel 9. Dampak Penyesuaian Threshold terhadap Metrik Evaluasi

Threshold	Precision	Recall	F1-Score	FN (Defect Tidak Terdeteksi)	FP (Inspeksi Tidak Perlu)
0,30	78,40%	98,50%	87,31%	7	127
0,40	85,60%	97,20%	91,04%	13	77
0,45	89,30%	96,80%	92,86%	15	54
0,50	91,19%	95,09%	93,10%	23	43
0,60	96,10%	85,30%	90,38%	69	16

Berdasarkan Tabel 9, *threshold* 0,45 dipilih sebagai titik operasional karena menghasilkan *Recall* 96,80% dengan hanya 15 unit *defect* yang tidak terdeteksi dari 468 unit *defect* aktual, dengan *trade-off Precision* yang masih dapat diterima sebesar 89,30% dan 54 unit *non-defect* yang salah ditahan untuk inspeksi tambahan. Dalam konteks produk keselamatan seperti ban, konsekuensi 15 unit *defect* yang lolos ke konsumen (FN) jauh lebih serius dibandingkan 54 unit baik yang salah ditahan untuk inspeksi tambahan (FP).

2. Sistem Alert Tiga Zona.

Berdasarkan *threshold* operasional 0,45 yang telah ditetapkan, sistem monitoring berbasis

probabilitas *defect* dirancang dengan tiga zona tindakan. Batas zona kuning atas sebesar 0,70 ditetapkan berdasarkan pertimbangan bahwa sampel dengan probabilitas *defect* $\geq 0,70$ menunjukkan keyakinan model yang tinggi terhadap status *defect* sehingga memerlukan eskalasi langsung tanpa menunggu inspeksi fisik tambahan:

- a. Zona Hijau ($P_{defect} < 0,45$): Produk lulus QC otomatis, proses dalam kendali, tidak diperlukan tindakan tambahan
- b. Zona Kuning ($0,45 \leq P_{defect} < 0,70$): Peringatan dini, diperlukan inspeksi fisik tambahan oleh teknisi QC sebelum keputusan final
- c. Zona Merah ($P_{defect} \geq 0,70$): Produk ditahan secara otomatis, eskalasi wajib ke supervisor QC, investigasi parameter proses segera dilakukan.

Implikasi Manajerial

Hasil penelitian memiliki tiga implikasi manajerial utama bagi PT Multistrada Arah Sarana Tbk. Pertama, dengan model yang mampu mendeteksi 96,80% unit *defect* pada *threshold* 0,45, perusahaan dapat mengintervensi proses sebelum unit *defect* selesai diproduksi, sehingga berpotensi mengurangi pemborosan bahan baku dan energi secara signifikan. Kedua, *feature importance* yang terperingkat secara kuantitatif memberikan panduan berbasis data bagi tim *engineering* untuk memprioritaskan pengendalian pada *Cure_Temperature* sebagai faktor dominan pertama (21,87%) dan *Cure_Pressure* sebagai faktor dominan keempat (10,98%), yang keduanya merupakan parameter proses yang dapat dikendalikan secara langsung melalui penyesuaian *setting* mesin vulkanisasi. Perlu dicatat bahwa *Uniformity_Index*, meskipun memiliki *feature importance* tinggi (17,54%), merupakan variabel output hasil pengukuran dan bukan parameter yang dapat dikendalikan secara langsung; rendahnya *Uniformity_Index* merupakan akibat dari ketidakstabilan *Cure_Temperature* dan *Cure_Pressure*. Ketiga, sistem *alert* tiga zona memungkinkan eskalasi respons yang proporsional terhadap tingkat risiko *defect*, mengoptimalkan alokasi sumber daya inspeksi secara efisien.

IV. KESIMPULAN

Penelitian ini berhasil mengintegrasikan kerangka *Six Sigma* DMAIC dengan algoritma *Random Forest* untuk mendukung pengendalian kualitas secara prediktif pada laboratorium industri ban. Integrasi tersebut menempatkan DMAIC sebagai kerangka perbaikan proses, sementara *Random Forest* berperan sebagai model analitik yang menghasilkan prediksi *defect* dan informasi mengenai faktor-faktor yang paling berpengaruh terhadap kualitas produk.

Hasil penelitian menunjukkan bahwa pendekatan yang diusulkan mampu memberikan kinerja klasifikasi yang tinggi sekaligus meningkatkan kemampuan deteksi dini terhadap produk *defect* dibandingkan pendekatan pengendalian kualitas konvensional. Selain menghasilkan prediksi yang akurat, model juga menyediakan informasi *feature importance* yang dapat digunakan untuk memprioritaskan parameter proses yang memerlukan tindakan pengendalian dan perbaikan. Dengan demikian, pengambilan keputusan dalam aktivitas *quality control* tidak lagi hanya bergantung pada inspeksi setelah proses selesai, tetapi dapat didukung oleh analisis prediktif berbasis data historis.

Kontribusi utama penelitian ini terletak pada integrasi fungsional antara DMAIC dan *Random Forest* dalam konteks pengendalian kualitas industri ban. Pendekatan ini memperluas pemanfaatan DMAIC dari kerangka perbaikan proses menjadi kerangka yang didukung kemampuan prediksi berbasis *machine learning* sehingga dapat membantu proses analisis, prioritas perbaikan, dan pengendalian kualitas secara lebih sistematis.

Penelitian ini masih memiliki beberapa keterbatasan, yaitu penggunaan data yang berasal dari satu perusahaan dan satu jenis proses pengujian sehingga generalisasi model pada lingkungan manufaktur lain masih perlu dibuktikan. Oleh karena itu, penelitian selanjutnya disarankan melakukan validasi pada data lintas perusahaan atau lintas lini produksi, mengeksplorasi algoritma *machine learning* lain seperti XGBoost atau LightGBM, serta mengembangkan pendekatan Explainable AI (misalnya SHAP) agar interpretasi hasil prediksi

semakin mendukung pengambilan keputusan di lingkungan industri.

V. REFERENSI

- Alkhatib, F., Allam, M., Swarnakar, V. et al. *Implementing and evaluating the quality 4.0 PMQ framework for process monitoring in automotive manufacturing*. Sci Rep 15, 24742 (2025). Nature.
<https://doi.org/10.1038/s41598-025-10226-4>
- Dogan, A., & Birant, D. (2021). *Machine Learning and Data Mining in Manufacturing*. Expert Systems with Applications, 166, 114060. Elsevier.
<https://doi.org/10.1016/j.eswa.2020.114060>
- Febriana, T. H., & Hasbullah, H. (2021). *Analysis and defect improvement using FTA, FMEA, and MLR through DMAIC phase: Case study in mixing process tire manufacturing industry*. Journal Européen des Systèmes Automatisés (JESA), 54(5), 721–731. International Information and Engineering Technology Association.
<https://doi.org/10.18280/jesa.540507>
- Santacruz, E., Romero, D., & Noguez, J., & Wuest, T. (2024). *Integrated quality 4.0 framework for quality improvement based on Six Sigma and machine learning techniques towards zero-defect manufacturing*. The TQM Journal, Vol. 37 No. 4 pp. 1115–1155. Emerald.
<https://doi.org/10.1108/TQM-11-2023-0361>
- Kausik, A., Rashid, A., Baki, R., & Maktum, M. (2025). *Machine learning algorithms for manufacturing quality assurance: A systematic review of performance metrics and applications*. Array. Elsevier
- Kumari, R., Singh, J., & Gosain, A. (2023). Impact of class imbalance ratio on ensemble methods for imbalance problem: A new perspective. *Journal of Intelligent & Fuzzy Systems*, 45(6), 10823–10834. Sage journals.
<https://doi.org/10.3233/JIFS-223333>
- Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., & Lee, S. I. (2020). *From Local Explanations to Global Understanding with Explainable AI for Trees*. Nature Machine Intelligence, 2(1), 56–67. Nature Publishing.
<https://doi.org/10.1038/s42256-019-0138-9>
- Mansour, H., Abohashima, H., Elkhoully, H.I., & Harraz, N.A. (2025). *Smart quality control: integrating six sigma, machine learning and real-time defect prediction in manufacturing*. International Journal of Lean Six Sigma, 16 (6): 1415–1447. Semantic Scholar.
- Mignot, T., Ponchon, F., Derville, A., et al. (2025). *From detections to decisions: An attention-guided deep multiple instance learning approach for visual tire inspection*. International Journal of Advanced Manufacturing Technology, 138, 5427–5442. Springer Nature.
<https://doi.org/10.1007/s00170-025-15740-3>
- Rajasekaran, S., Turanoglu Bekar, E., Gandhi, K., Roselli, S. F., & Rajashekarappa, M. (2026). *Machine learning-based analysis of critical process parameters influencing product quality defects: A real-world case study in manufacturing*. arXiv preprint, arXiv:2603.11666.
- Sütöová, A., et al. (2026). *Integration of Six Sigma DMAIC methodology with machine learning in quality improvement: an application in the casting manufacturing process*. International Journal of Advanced Manufacturing Technology. Springer Nature.
<https://doi.org/10.1007/s00170-026-18472-0>
- Uluskan, M., & Karşı, M. G. (2022). *Predictive Six Sigma for Turkish manufacturers: utilization of machine learning tools in DMAIC*. International Journal of Lean Six Sigma, 14(3), 630–652. Emerald.
<https://doi.org/10.1108/IJLSS-02-2022-0046>
- Yorulmuş, M. H., Bolat, H.B.S. & Bahadır, M. (2026). *Predictive Quality Defect Detection Using Machine Learning Algorithms: A Case Study from Automobile Industry*. in INFUS 2021: Intelligent and Fuzzy Techniques for Emerging Conditions and Digital Transformation, Lecture Notes in Networks and Systems, vol. 307, Multidisciplinary Digital Publishing Institute.
<https://doi.org/10.3390/asi9070132>