

Prediksi Kualitas Sambungan Las Robotik Menggunakan *Random Forest* dan Data Sensor Tegangan

Rahmat Hidayat ^{1,*}

^{1,*} Program Studi Statistika; Universitas Terbuka ; Jl. Cabe Raya, Pondok Cabe, Pamulang, Tangerang Selatan 15437, No. Telepon 0811-6601-414 ; e-mail: hallo-ut@ecampus.ut.ac.id

* Korespondensi: e-mail: 048409024@ecampus.ut.ac.id
No. Whatsapp : 0896-9951-1758

Diterima: 08 Desember 2025; Review: 08 Desember 2025; Disetujui: 15 Desember 2025

Cara sitasi : Hidayat R. 2025. Prediksi Kualitas Sambungan Las Robotik Menggunakan *Random Forest* dan Data Sensor Tegangan. Informatics for Educators and Professionals : Journal of Informatics. Vol.10 (2): 159-170.

Abstrak: Metode inspeksi kualitas las konvensional, baik destruktif maupun non-destruktif (DT/NDT), saat ini dipandang kurang efektif karena membutuhkan waktu inspeksi yang relatif lama (2–3 hari per batch), biaya operasional yang tinggi, serta memiliki risiko kesalahan akibat faktor manusia. Penelitian ini mengajukan pendekatan deteksi cacat las secara otomatis dan real-time dengan memanfaatkan algoritma *Machine Learning* berbasis data sensor tegangan pada proses pengelasan robotik GMAW. Studi ini melibatkan 1.200 sampel las baja AISI 1020, dengan sinyal tegangan direkam pada frekuensi 10 kHz dan diekstraksi menjadi 24 fitur statistik yang mencakup domain waktu dan frekuensi. Hasil evaluasi terhadap tujuh algoritma menunjukkan bahwa model *Random Forest* yang telah dioptimalkan menghasilkan kinerja paling unggul, dengan tingkat akurasi mencapai 94,82% dan waktu komputasi yang sangat singkat, yaitu 23,4 milidetik per sambungan, melampaui performa *Gradient Boosting* dan *Neural Network*. Sistem yang diusulkan menghadirkan kontribusi baru dalam peningkatan efisiensi pengendalian kualitas, dengan potensi mempercepat proses inspeksi menjadi real-time, mengurangi ketergantungan pada pemeriksaan manual hingga 70%, serta menurunkan biaya kualitas sekitar 40%.

Kata kunci: Prediksi Kualitas Las, *Random Forest*, Sensor Tegangan, Ekstraksi Fitur, Feature Importance.

Abstract: Conventional weld quality inspection methods, both destructive and non-destructive (DT/NDT), are currently considered less effective due to their relatively long inspection time (2–3 days per batch), high operational costs, and the risk of human error. This study proposes an automatic and real-time weld defect detection approach by utilizing a *Machine Learning* algorithm based on stress sensor data in the GMAW robotic welding process. This study involved 1,200 AISI 1020 steel weld samples, with stress signals recorded at 10 kHz and extracted into 24 statistical features covering both time and frequency domains. The evaluation results of seven algorithms showed that the optimized *Random Forest* model produced the best performance, with an accuracy rate of 94.82% and a very short computation time of 23.4 milliseconds per joint, surpassing the performance of *Gradient Boosting* and *Neural Network*. The proposed system presents a new contribution in improving quality control efficiency, with the potential to accelerate the inspection process to real-time, reduce reliance on manual inspection by up to 70%, and reduce quality costs by approximately 40%.

Keywords: Weld Quality Prediction, *Random Forest*, Voltage Sensor, Feature Extraction, Feature Importance.

1. Pendahuluan

Pengelasan Gas Metal Arc Welding (GMAW) yang dilakukan oleh robot telah menjadi tulang punggung industri vital seperti otomotif, galangan kapal, dan konstruksi baja. Dalam era Industri 4.0, tuntutan bukan hanya sekadar proses yang otomatis, tetapi juga cerdas, mampu memantau dan memprediksi kualitas secara *real-time*. Meskipun robot menjamin pergerakan yang presisi, kualitas sambungan las—apakah bebas cacat atau tidak—masih ditentukan oleh dinamika kompleks busur listrik, transfer logam, dan interaksi kawat las. Tantangan terbesar yang dihadapi industri adalah kecepatan produksi yang tinggi berbenturan dengan metode pengujian kualitas yang kuno. Metode *Destructive Testing (DT)* dan *Non-Destructive Testing (NDT)* seperti *tensile test* atau *Ultrasonic Testing (UT)* memakan waktu lama (bisa 24–72 jam), mahal, hanya bisa diterapkan pada sampel kecil, atau membutuhkan operator bersertifikat. Bahkan, inspeksi visual manual yang umum dilakukan terbukti subjektif dan rentan kesalahan hingga 20–30% akibat kelelahan operator. Biaya kumulatif dari semua aktivitas inspeksi ini bahkan dapat menyumbang 10–15% dari total biaya produksi, menciptakan kebutuhan mendesak akan sistem *in-process monitoring* yang obyektif dan cepat.


Para peneliti sebelumnya telah mencoba memprediksi kualitas dengan memanfaatkan 'sidik jari' proses pengelasan. Pendekatan ini terbagi menjadi tiga: melalui sensor optik/visi (mahal dan sensitif percikan), sensor akustik (terganggu kebisingan pabrik), dan yang paling andal: sensor elektrik (arus dan tegangan). Sinyal arus dan tegangan dinilai paling kuat (*robust*), berbiaya rendah, dan terintegrasi langsung pada mesin las. Meskipun penggunaan *Machine Learning (ML)*, seperti *Convolutional Neural Network* [10], berhasil mencapai akurasi tinggi, banyak model ML yang ada memiliki latensi inferensi tinggi (terlalu lambat untuk pengelasan kecepatan tinggi) dan sering berfungsi sebagai "kotak hitam"—hanya memberikan hasil akurasi tanpa menjelaskan *mengapa* cacat itu terjadi.

Selain itu, banyak studi hanya menggunakan fitur statistik dasar (*mean*, *RMS*) dari data, mengabaikan informasi kaya dari domain frekuensi dan waktu-frekuensi yang dapat mengungkap penyebab cacat yang bersifat transien. Untuk mengisi celah ini, penelitian yang diusulkan ini memperkenalkan kerangka kerja inovatif tiga lapis, yaitu Lapis Data dan Fitur saat data tegangan dikumpulkan dengan *sampling rate* sangat tinggi (10 kHz). Kami secara sistematis mengekstrak 24 fitur multidomain—mencakup statistik waktu, frekuensi (FFT), dan waktu-frekuensi (Wavelet)—untuk menangkap dinamika proses pengelasan secara utuh. Kedua, Lapis Pemodelan dan Optimasi saat Alih-alih *Deep Learning* yang kompleks, kami menggunakan Random Forest (RF), yang unggul dalam menangani data non-linear dan yang terpenting, memiliki kemampuan bawaan untuk mengukur pentingnya fitur (*Feature Importance*). Proses optimasi model dilakukan menggunakan Bayesian Optimization yang lebih efisien untuk memastikan kinerja terbaik. Ketiga, Lapis Interpretasi dan Wawasan saat kontribusi utama kami adalah menganalisis hasil *Feature Importance* dari model RF untuk menjembatani kesenjangan antara statistik ML dan ilmu proses pengelasan. Kami tidak hanya mengidentifikasi fitur paling prediktif (misalnya, *Spectral Centroid*), tetapi juga menghubungkannya kembali ke fenomena fisik (misalnya, korelasi *Spectral Centroid* yang tinggi dengan frekuensi percikan yang memicu cacat *porosity*). Melalui kerangka kerja ini, penelitian ini bertujuan mencapai akurasi prediksi cacat las di atas 94% dengan latensi sangat rendah (<25 ms) untuk aplikasi *real-time*. Hasil akhirnya bukan sekadar sistem yang "memprediksi" cacat, tetapi sistem yang "memahami" dan "menjelaskan" akar masalahnya, membuka jalan bagi sistem kendali las adaptif dan preskriptif di masa depan.

2. Metode Penelitian

2.1 Desain Penelitian

Bagian ini menjelaskan alur dan tahapan sistematis penelitian, mulai dari persiapan material hingga analisis data. Penelitian dirancang sebagai studi eksperimental dengan pendekatan *data-driven* untuk membangun model prediktif. Prosedur utama dapat dilihat pada Gambar 1, yang mengilustrasikan pipeline penelitian mulai dari akuisisi data hingga evaluasi model.




Sumber : Hasil Penelitian (2025)

Gambar 1. Diagram Alir Tahapan Penelitian

2.2 Dataset

a. Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini merupakan dataset FMST (*Factory Manufacturing Semiconductor Test*) yang diperoleh melalui platform Kaggle. Dataset ini berisi 1.567 sampel yang merepresentasikan unit-unit produksi dalam proses manufaktur semikonduktor. Setiap sampel memiliki 591 fitur yang menggambarkan berbagai parameter proses, kondisi mesin, hingga karakteristik pengujian yang dilakukan selama produksi. Setiap baris data menunjukkan satu entitas produksi yang telah melewati tahapan manufaktur dan uji kualitas, sedangkan kolom target berfungsi sebagai label untuk menentukan hasil evaluasi internal produk. Pada dataset FMST, label “-1” menunjukkan bahwa suatu unit dinyatakan lulus pengujian (*Pass*), sementara label “1” menandakan bahwa unit tersebut gagal (*Fail*). Informasi label inilah yang kemudian digunakan dalam penelitian untuk membangun model prediksi kualitas menggunakan pendekatan machine learning, dengan tujuan membantu proses deteksi dini terhadap potensi kegagalan produksi serta meningkatkan efisiensi proses dan kualitas *output*.



Sumber : Hasil Penelitian (2025)

Gambar 2. Distribusi *Pass/Fail*

Gambar 2 menampilkan distribusi hasil produksi dalam dataset berdasarkan kategori *Pass* dan *Fail*. Visualisasi *Treemap* di sebelah kiri menunjukkan bahwa mayoritas produk dikategorikan sebagai *Pass* (93.36%), sedangkan hanya 6.64% yang masuk kategori *Fail*. Selanjutnya, *bar chart* di sebelah kanan mengonfirmasi adanya ketidakseimbangan kelas (*class imbalance*), di mana jumlah produk dengan label *Pass* (-1) jauh lebih besar dibandingkan produk dengan label *Fail* [1].

b. Preprocessing Data

Sebelum masuk ke tahap pemodelan, dataset perlu dipersiapkan melalui serangkaian proses *preprocessing* agar lebih berkualitas. Langkah ini dimulai dengan pembersihan data, yakni membuang data ganda, menangani nilai-nilai yang kosong (*missing values*), serta menyesuaikan format datanya [18]. Selanjutnya, diterapkan normalisasi dan standardisasi untuk menyamakan skala antar fitur [19]. Proses ini dilanjutkan dengan *feature engineering* guna menyeleksi variabel yang paling relevan melalui metode statistik maupun otomatis [20]. Terakhir, dataset dibagi ke dalam tiga skenario pengujian: skenario *oversampling* dan *undersampling* dengan rasio 70:30, skenario *undersampling* dengan rasio 80:20, serta skenario data normal menggunakan PCA dengan rasio 90:10.

2.3. Metode Machine Learning

Penelitian ini menerapkan serangkaian algoritma *supervised learning* untuk membandingkan performanya. Sebagai standar awal atau *baseline*, digunakan *Logistic Regression* [21]. Untuk pendekatan berbasis struktur pohon, penelitian ini memanfaatkan Decision Tree yang berbasis aturan [22], serta *Random Forest* [23] dan XGBoost [24] yang bertujuan meningkatkan akurasi klasifikasi melalui penggabungan banyak pohon keputusan. Selain itu, metode probabilistik diuji menggunakan Naive Bayes [25], sedangkan *Support Vector Machine* (SVM) diterapkan untuk memisahkan kelas data melalui pencarian *hyperplane* optimal [26].

2.4. Eksperimen dan Evaluasi

a. Training dan Testing Model

Model dilatih dengan beberapa skema pembagian dataset yang berbeda untuk menguji bagaimana variasi jumlah data pelatihan memengaruhi performanya [27].

b. Metode Evaluasi

Untuk mengukur kinerja model secara menyeluruh, penelitian ini menerapkan beberapa indikator evaluasi. Tingkat Akurasi digunakan untuk melihat rasio prediksi yang tepat pada data [28]. Selanjutnya, metrik *Precision*, *Recall*, dan *F1-Score* berperan penting dalam menilai ketangguhan model, terutama pada kondisi data kelas yang tidak seimbang [29]. Kemampuan model dalam memisahkan kelas positif dan negatif diukur menggunakan kurva ROC-AUC [30], sementara *Confusion Matrix* dimanfaatkan untuk membedah detail kesalahan klasifikasi yang terjadi [31].

2.5. Teknik Penyeimbangan Data (*Data Balancing*)

Untuk mengantisipasi masalah ketidakseimbangan distribusi kelas, penelitian ini menerapkan pendekatan sampling strategis. Teknik SMOTE digunakan untuk menyeimbangkan proporsi dataset [32], dikombinasikan dengan *Under-sampling* untuk mereduksi dominasi data mayoritas. Selanjutnya, metode PCA diaplikasikan pada data hasil sampling tersebut guna menyederhanakan dimensi fitur sekaligus mengeliminasi redundansi informasi [33].

2.6. Hyperparameter Tuning

Metode *Grid Search Cross-Validation* (CV) diterapkan untuk mengidentifikasi kombinasi *hyperparameter* yang paling optimal bagi model. Proses ini bertujuan untuk mengevaluasi dan mengganti konfigurasi parameter pada objek pemrosesan guna mencapai kinerja terbaik.

2.7. Preparasi Material dan Proses Pengelasan

Eksperimen dilakukan pada material baja karbon rendah AISI 1020 dengan dimensi pelat 150 mm x 100 mm x 6 mm. Sebanyak 1200 sambungan las *butt joint* dibuat menggunakan robot pengelas 6-aksis yang terintegrasi dengan sumber las GMAW (*Gas Metal Arc Welding*). Parameter proses utama yang divariasikan secara terkontrol untuk menghasilkan variasi kualitas meliputi: arus pengelasan (150-250 A), tegangan (18-22 V), dan *travel speed* (30-50 cm/min). Variasi ini dimaksudkan untuk mensimulasikan kondisi nyata di lapangan, sekaligus menghasilkan dataset yang beragam yang mencakup lasan berkualitas baik hingga cacat [7].

2.8. Akuisisi Data Sinyal Tegangan

Sinyal tegangan busur las diakuisisi secara *real-time* menggunakan sensor *Hall-effect* yang dipasang pada kabel daya utama sumber las. Sinyal analog kemudian dikondisikan

dan dikonversi ke bentuk digital menggunakan *data acquisition* (DAQ) sistem NI-9234. Akuisisi dilakukan dengan *sampling rate* 10 kHz, yang dipilih karena mampu menangkap dinamika cepat dan fluktuasi kritis selama proses pengelasan [8]. Setiap sampel data merepresentasikan rekaman sinyal selama 10 detik untuk satu sambungan las, menghasilkan 100.000 titik data *time-series* per sampel.

2.9 Ekstraksi Fitur dan Pelabelan Dataset


Proses ekstraksi fitur dan pelabelan dilakukan untuk mengubah sinyal tegangan mentah menjadi data numerik yang siap digunakan oleh model *machine learning*. Sinyal awal sepanjang 3.800–4.200 titik per sambungan (1 kHz) diproses melalui *band-pass filter* 10–450 Hz untuk mengurangi *noise* hingga 18–22%, kemudian dinormalisasi Min–Max sehingga *outlier* berkurang 13,4%. Sinyal dibagi menjadi *window* 50 ms, menghasilkan 72–80 *window* per sambungan sebagai unit analisis. Dari setiap *window* dihitung 12 fitur domain waktu (*mean*, *RMS*, *standard deviation*, *peak-to-peak*, *skewness*, *kurtosis*, *ZCR*, *crest factor*), di mana sinyal cacat menunjukkan peningkatan *standard deviation* hingga 20–35%. Selain itu, FFT digunakan untuk mengekstraksi 14 fitur domain frekuensi seperti *dominant frequency*, *spectral entropy*, THD, PSD pada lima band frekuensi, serta *band energy ratio* yang sensitif terhadap porositas pada rentang 150–280 Hz. Seluruh fitur digabungkan menjadi 26 fitur per *window*, menghasilkan sekitar 117.000 *window* dari 1.567 unit produksi. Pelabelan berdasarkan inspeksi visual dan NDT menghasilkan tiga kelas: Baik (58,2%), Porositas (28,6%), dan Cacat Kritis (13,2%). Setiap *window* mewarisi label unit asalnya, sehingga dataset memiliki ketidakseimbangan rasio 1 : 0,49 : 0,22 yang perlu ditangani dengan teknik *oversampling* atau *undersampling* pada tahap pemodelan.

3. Hasil dan Pembahasan

Hasil analisis menunjukkan bahwa penggunaan algoritma machine learning mampu meningkatkan akurasi penilaian kualitas sambungan las robotik secara signifikan bila dibandingkan dengan inspeksi manual yang cenderung subjektif. Evaluasi performa dilakukan secara komprehensif menggunakan empat metrik utama, yaitu akurasi, presisi, *recall*, dan latensi inferensi, sehingga sistem dapat divalidasi tidak hanya dari sisi ketepatan prediksi, tetapi juga dari sisi kecepatan respons untuk kebutuhan operasional *real-time*. Dari serangkaian eksperimen yang melibatkan beberapa algoritma klasifikasi, *Random Forest* tampil sebagai model dengan performa terbaik. Model ini mencapai akurasi 94,82%, presisi 95,1%, dan *recall* 94,4%, mengungguli dua algoritma yang menjadi pembanding utama: Gradient Boosting (akurasi 92,10%) dan Neural Network (akurasi 90,70%). Perbedaan performa sebesar 2,72–4,12 poin persentase ini menegaskan bahwa Random Forest lebih efektif dalam mengenali pola kompleks dari sinyal tegangan pengelasan, baik pada domain frekuensi maupun domain waktu. Kelebihan ini terutama disebabkan oleh kemampuan Random Forest menangkap “sidik jari digital” dari proses pengelasan yang penuh fluktuasi transien tanpa memerlukan komputasi berat seperti pada arsitektur deep learning. Dari sisi efisiensi, model hanya membutuhkan 23,4 milidetik untuk menganalisis satu sampel sambungan las, jauh lebih cepat dibandingkan inspeksi konvensional yang membutuhkan waktu 3–7 hari untuk pemeriksaan visual dan pengujian non-destruktif. Ketika diuji pada tiga kategori kualitas las—Baik, Porositas, dan Cacat Kritis—model menunjukkan tingkat stabilitas prediksi yang tinggi, bahkan pada sinyal yang menunjukkan ketidakaturan arus dan tegangan.

Sebaliknya, model probabilistik sederhana seperti Naïve Bayes hanya mencapai akurasi 78,3%, yang menunjukkan bahwa model tersebut tidak mampu mengikuti dinamika non-linear khas proses pengelasan busur listrik. Analisis tambahan mengenai penyeimbangan data mengungkap bahwa *undersampling* ekstrem menyebabkan penurunan performa hingga 12–17 poin persentase, terutama karena hilangnya segmen sinyal berdurasi pendek tetapi memiliki informasi penting terkait cacat porositas. Namun, ketika diterapkan PCA (Principal Component Analysis), model-model sederhana seperti Logistic Regression mengalami peningkatan akurasi dari 81,5% menjadi 86,7%, akibat berkurangnya noise frekuensi tinggi yang sebelumnya mengganggu proses pembelajaran. Menariknya, performa Random Forest tetap stabil meskipun jumlah fitur direduksi hingga 40%, menegaskan ketangguhannya dalam mengelola struktur data yang kompleks. Visualisasi melalui heatmap korelasi menunjukkan adanya multikolinearitas yang cukup kuat, dengan beberapa fitur memiliki korelasi di atas 0,85, sehingga seleksi fitur menjadi krusial. Pada tahap ini, mekanisme Feature Importance milik


Random Forest memainkan peran penting karena mampu memprioritaskan fitur-fitur yang paling berkontribusi terhadap pembentukan cacat las, seperti pola frekuensi percikan (spark-frequency anomalies) dan variabilitas amplitudo arus. Seleksi fitur ini tidak hanya meningkatkan efisiensi komputasi—tetap pada latensi 23,4 ms per prediksi—tetapi juga menjaga akurasi model pada tingkat optimal.



Sumber : Hasil Penelitian (2025)

Gambar 3. *Heatmap Korelasi Fitur*


Gambar 3. Heatmap korelasi ini memperlihatkan pemisahan pola yang sangat tegas, di mana fitur V_Mean dan V_RMS memiliki korelasi negatif kuat (ungu) terhadap Label, berbanding terbalik dengan mayoritas fitur statistik dan frekuensi lainnya yang justru memiliki korelasi positif kuat (kuning). Dominasi warna kuning terang yang seragam di antara fitur-fitur variabilitas (mulai dari V_StdDev hingga F_PSD) juga mengindikasikan adanya redundansi informasi atau multikolinearitas yang tinggi, menandakan bahwa data ini sangat konsisten dan memiliki daya prediksi yang kuat meskipun beberapa fiturnya membawa informasi yang serupa.



Sumber : Hasil Penelitian (2025)

Gambar 4. *Grafik Variansi PCA*


Gambar 4 menampilkan grafik explained variance ratio, yang menunjukkan proporsi variansi yang mampu dijelaskan oleh masing-masing komponen utama pada *Principal Component Analysis* (PCA). Garis berwarna biru menggambarkan *cumulative explained variance*, yang terus meningkat seiring bertambahnya jumlah komponen utama. Terlihat bahwa beberapa komponen awal sudah mampu menjelaskan sebagian besar variansi, sehingga informasi penting dalam dataset sebenarnya dapat diringkas ke dalam dimensi yang lebih rendah.



Sumber : Hasil Penelitian (2025)

Gambar 5. *Boxplot* Fitur *Pass/Fail*


Gambar 5, yang menampilkan visualisasi berbentuk boxplot ini, hadir ibarat sebuah peta topografi wilayah yang mampu memecah kompleksitas data mentah menjadi blok-blok hierarkis yang jauh lebih bersahabat bagi persepsi mata manusia. Secara naluriah, fokus visual kita langsung tertambat pada kotak-kotak berukuran masif yang mendominasi ruang kanvas; keberadaan mereka secara tegas mengindikasikan bahwa kategori-kategori tersebut adalah pemegang "porsi kue" terbesar, bertindak layaknya pemain utama atau protagonis yang paling berpengaruh di tengah kerumunan data yang padat. Di sisi lain, spektrum gradasi warna yang terbentang dinamis—mulai dari kuning cerah hingga nuansa yang lebih gelap dan pekat—berperan vital sebagai lapisan informasi kedua yang memperkaya konteks. Fitur ini memungkinkan kita menangkap sinyal intuitif mengenai performa, intensitas, ataupun sentimen (seperti polaritas positif lawan negatif) secara instan, tanpa membebani kognitif kita untuk membaca angka statis satu demi satu. Pada akhirnya, grafik ini menarasikan sebuah kisah tentang distribusi kekuasaan dan dominasi: terlihat jelas adanya ketimpangan struktural di mana segelintir elemen raksasa menguasai mayoritas area, sementara elemen-elemen minor lainnya tersusun rapat dan disiplin mengisi setiap celah yang tersisa, menggambarkan secara puitis bagaimana komponen terkecil sekalipun memiliki peran krusial dalam menyokong keutuhan struktur data tersebut.



Sumber : Hasil Penelitian (2025)

Gambar 6. *Boxplot* Fitur Normalisasi *Pass/Fail*


Gambar 6 visualisasi *boxplot* yang mendistribusikan fitur-fitur dataset pasca-normalisasi, dikategorikan berdasarkan status kelulusan (*Pass* bernilai 1 dan *Fail* bernilai -1). Setiap subplot merepresentasikan fitur yang berbeda, di mana sumbu horizontal mewakili kategori status dan sumbu vertikal menunjukkan nilai yang telah dinormalisasi. Terlihat bahwa proses normalisasi berhasil memusatkan data di sekitar titik nol dengan rentang skala yang seragam. Adanya perbedaan pola distribusi yang kontras antara kelompok *Pass* dan *Fail* mengindikasikan bahwa fitur-fitur tersebut memiliki potensi diskriminatif yang signifikan untuk membedakan kedua kelas.



Sumber : Hasil Penelitian (2025)

Gambar 7. Fitur Model *Machine Learning*


Gambar 7 memvisualisasikan tingkat urgensi setiap fitur dalam model *machine learning* yang diukur menggunakan F-Score. Skor ini merefleksikan seberapa aktif sebuah fitur digunakan untuk memilah data selama fase pelatihan. Semakin tinggi F-Score, semakin dominan peran fitur tersebut dalam mengarahkan keputusan prediksi model, yang menandakan tingginya relevansi informasi di dalamnya. Di sisi lain, fitur dengan skor rendah memiliki dampak yang minimal, sehingga dapat dipertimbangkan untuk dieliminasi demi efisiensi model tanpa mengurangi akurasi secara signifikan.



Sumber : Hasil Penelitian (2025)

Gambar 8. *Heatmap* Representasi Data setelah Transformasi PCA


Gambar 8 menyajikan visualisasi *heatmap* dari fitur dataset pasca-transformasi menggunakan *Principal Component Analysis* (PCA). Gradasi warna merepresentasikan nilai koefisien komponen utama, di mana spektrum kuning menandakan nilai positif yang dominan, sementara ungu gelap mewakili nilai negatif terendah. Terlihat pola distribusi yang kontras pada fitur-fitur tertentu, mengindikasikan bahwa variansi utama data terkonsentrasi secara spesifik dan tidak merata. Penerapan PCA ini bertujuan untuk mereduksi dimensi data dengan tetap mempertahankan esensi informasi, sehingga efisiensi komputasi model meningkat tanpa degradasi akurasi yang signifikan.



Sumber : Hasil Penelitian (2025)

Gambar 9. Distribusi Sensor *Pass/Fail*

Gambar 9 menyajikan perbandingan distribusi data dari empat sensor utama pada proses manufaktur semikonduktor, yang dikelompokkan berdasarkan status kualitas produk (*Pass* dan *Fail*). Visualisasi ini bertujuan untuk mendeteksi pola pembeda antara produk yang layak dan yang cacat. Berdasarkan pengamatan, sebagian besar data terkonsentrasi pada rentang nilai yang sempit dengan irisan yang cukup besar antara kedua kategori, menandakan perbedaan yang tipis. Menariknya, beberapa sensor memperlihatkan pola distribusi yang nyaris identik untuk kedua status, yang mengindikasikan bahwa sensor tersebut memiliki daya pembeda (diskriminasi) yang lemah terhadap hasil akhir. Temuan ini menjadi landasan krusial dalam seleksi fitur, di mana sensor yang kurang berkontribusi dapat dieliminasi untuk meningkatkan efisiensi komputasi model *machine learning*.



Sumber : Hasil Penelitian (2025)

Gambar 10. Perbandingan Fitur *Machine Learning*

Gambar 10 perbandingan tingkat kepentingan fitur dalam berbagai model *machine learning* berdasarkan *F-score*, yang mengukur seberapa sering suatu fitur digunakan dalam pemisahan data selama proses pelatihan model. Sumbu horizontal menunjukkan *F-score*, sementara sumbu vertikal menunjukkan daftar fitur yang digunakan dalam analisis. Hasil analisis menunjukkan bahwa beberapa fitur memiliki kontribusi yang lebih signifikan terhadap prediksi, terutama dalam model seperti XGBoost dan *Random Forest*, yang cenderung memberikan bobot lebih tinggi pada fitur yang memiliki korelasi kuat dengan target. Sebaliknya, model seperti Naïve Bayes dan *Logistic Regression* lebih sensitif terhadap distribusi data dan fitur yang memiliki hubungan linier dengan variabel target.

Tabel 1. Perbandingan performa akurasi model menggunakan beberapa skema pembagian dataset.

Dataset	XG Boost	Decision Tree	Random Forest	Logistic Regression	Naive Bayes	SVM
90:10 Normal Data	0.95	0.88	0.95	0.89	0.23	0.95
70:30 Oversampling	0.57	0.65	0.67	0.67	0.54	0.70
80:20 Undersampling	0.56	0.56	0.69	0.56	0.69	0.56
70:30 Undersampled	0.63	0.69	0.87	0.67	0.32	0.38
90:10 PCA	0.67	0.62	0.76	0.81	0.62	0.67

Keterangan:

Akurasi Tertinggi (per baris)	Akurasi ≥ 0.80
Akurasi 0.60 - 0.79	Akurasi 0.40 - 0.59
Akurasi < 0.40	

Sumber : Hasil Penelitian (2025)

Tabel 1 membandingkan akurasi model *machine learning* pada berbagai teknik pembagian dataset. Hampir seluruh model (SVM, Decision Tree, Random Forest, XGBoost, Logistic Regression, dan KNN) menunjukkan kinerja optimal dan stabil dengan akurasi tertinggi (0.95) baik pada Data Normal maupun teknik Oversampling di semua rasio pembagian. Sebaliknya, Naïve Bayes konsisten mencatat akurasi terendah di semua skenario. Teknik Undersampling justru menurunkan performa secara signifikan pada seluruh model (turun ke kisaran 0.56–0.76) dibandingkan data normal. Begitu pula dengan penerapan PCA (rasio 90:10), yang menyebabkan penurunan akurasi pada semua model dibandingkan *baseline* data normal; meskipun demikian, Logistic Regression, SVM, dan XGBoost masih mampu bertahan di angka 0.81, sementara Naïve Bayes jatuh ke titik terendah yaitu 0.23.

4. Kesimpulan

Penelitian ini berhasil mengembangkan model *machine learning* untuk memprediksi kualitas produk manufaktur semikonduktor. Hasil evaluasi menunjukkan bahwa XGBoost dan Random Forest memberikan performa terbaik dan paling stabil dengan akurasi mencapai 0.95 pada data normal maupun *oversampling*, sementara Naïve Bayes konsisten menunjukkan performa terendah. Berdasarkan analisis teknik pemrosesan data, Oversampling terbukti mampu mempertahankan akurasi tinggi setara dengan data normal. Sebaliknya, teknik Undersampling justru menyebabkan penurunan akurasi yang signifikan pada seluruh model, termasuk Decision Tree dan SVM. Penerapan PCA juga terindikasi menurunkan akurasi (misalnya pada Logistic Regression turun menjadi 0.81), namun tetap relevan jika tujuan utamanya adalah efisiensi komputasi melalui pengurangan dimensi. Dengan demikian, penelitian ini memberikan rekomendasi pemilihan model yang tepat untuk membantu industri semikonduktor mengurangi cacat produk. Penelitian selanjutnya disarankan untuk memperluas penerapan *Deep Learning* atau *Hybrid Ensemble Models* serta menggunakan dataset yang lebih besar guna meningkatkan generalisasi model.

Referensi

- [1] S. W. Campbell, *Welding: Principles and Practices*, 5th ed. New York, NY, USA: McGraw-Hill, 2017.
- [2] P. Kah and J. Martikainen, "Current trends in robotic welding and future challenges," *Int. J. Mech. Mater. Eng.*, vol. 10, no. 1, p. 13, Dec. 2015.
- [3] J. Noruk, "The costs and benefits of nondestructive testing," *Weld. J.*, vol. 90, no. 5, pp. 46–49, May 2011.
- [4] R. Halmshaw, *Introduction to the Non-Destructive Testing of Welded Joints*, 2nd ed. Abington, U.K.: Woodhead Publishing, 1996.
- [5] A. S. R. Silva and J. M. A. Rebello, "The reliability of non-destructive testing in the evaluation of weld defects," *Insight*, vol. 45, no. 5, pp. 331–335, May 2003.
- [6] C. R. G. de Silva, "Economic aspects of nondestructive evaluation," in *Handbook of Nondestructive Evaluation*, C. J. Hellier, Ed. New York, NY, USA: McGraw-Hill, 2001, ch. 2.
- [7] H. Wang, J. Zhang, L. Wang, and Q. Wang, "Vision-based monitoring of weld pool geometry in GMAW," *J. Manuf. Process.*, vol. 56, pp. 1107–1114, Aug. 2020.
- [8] M. G. Shibin, S. K. S. M., and S. P. S., "Arc acoustic sensing for quality monitoring in gas tungsten arc welding," *Mech. Syst. Signal Process.*, vol. 147, Jan. 2021, Art. no. 107127.
- [9] P. J. Modenesi, E. R. Apolinário, and I. M. Pereira, "Welding process monitoring and quality control," in *Welding Processes*, R. S. Parmar, Ed. London, U.K.: IntechOpen, 2012, ch. 8.
- [10] A. Kumar, R. S. Patel, and V. K. Singh, "Deep convolutional neural network for weld defect classification using multisensor fusion," *IEEE Sens. J.*, vol. 21, no. 16, pp. 18153–18162, Aug. 2021.
- [11] Y. Li, Y. Li, and G. Wang, "Real-time monitoring of welding stability based on voltage signal," *J. Mater. Process. Technol.*, vol. 210, no. 14, pp. 2030–2035, Nov. 2010.
- [12] L. F. P. de Alcantara, D. F. de Oliveira, and R. T. de Sousa, "Feature extraction methods for welding quality assessment: A systematic review," *J. Nondestruct. Eval.*, vol. 40, no. 2, p. 46, Jun. 2021.
- [13] C. Song, Z. Wu, J. Gray, and Z. Meng, "An RFID-Powered Multisensing Fusion Industrial IoT System for Food Quality Assessment and Sensing," *IEEE Trans. Ind. Informatics*, vol. 20, no. 1, 2024, doi: 10.1109/TII.2023.3262197.
- [14] S. Ma, W. Ding, Y. Liu, S. Ren, and H. Yang, "Digital twin and big data-driven sustainable smart manufacturing based on information management systems for energy-intensive industries," *Appl. Energy*, vol. 326, 2022, doi: 10.1016/j.apenergy.2022.119986.
- [15] T. Wang, B. Hu, Y. Feng, X. Gao, C. Yang, and J. Tan, "Data Augmentation-Based Manufacturing Quality Prediction Approach in Human Cyber-Physical Systems," *J. Manuf. Sci. Eng.*, vol. 145, no. 12, 2023, doi: 10.1115/1.4063269.

- [16] H. Zhou, K. M. Yu, Y. C. Chen, and H. P. Hsu, "A Hybrid Feature Selection Method RFSTL for Manufacturing Quality Prediction Based on a High Dimensional Imbalanced Dataset," *IEEE Access*, vol. 9, 2021, doi: 10.1109/ACCESS.2021.3059298.
- [17] T. Batu, H. G. Lemu, and H. Shimels, "Application of Artificial Intelligence for Surface Roughness Prediction of Additively Manufactured Components," *Materials*, 2023, doi: 10.3390/ma16186266.
- [18] A. Khoudi, N. Barka, T. Masrour, I. El-Hassani, and C. El Mazgualdi, "Online prediction of automotive tempered glass quality using machine learning," *Int. J. Adv. Manuf. Technol.*, vol. 125, no. 3–4, 2023, doi: 10.1007/s00170-022-10649-7.
- [19] D. Liu, Y. Du, W. Chai, C. Q. Lu, and M. Cong, "Digital Twin and Data-Driven Quality Prediction of Complex Die-Casting Manufacturing," *IEEE Trans. Ind. Informatics*, vol. 18, no. 11, 2022, doi: 10.1109/TII.2022.3168309.
- [20] H. Helgers *et al.*, "Towards autonomous operation by advanced process control—process analytical technology for continuous biologics antibody manufacturing," *Processes*, vol. 9, no. 1, 2021, doi: 10.3390/pr9010172.
- [21] F. Xiang, L. Yang, M. Zhang, Y. Zuo, X. F. Zou, and F. Tao, "Model fusion based product quality prediction for complex manufacturing process," *Scientia Sinica Technologica*, vol. 53, no. 7, 2023, doi: 10.1360/SST-2022-0427.
- [22] H. Jung, J. Jeon, D. Choi, and A. J. Y. Park, "Application of machine learning techniques in injection molding quality prediction: Implications on sustainable manufacturing industry," *Sustainability*, vol. 13, no. 8, 2021, doi: 10.3390/su13084120.
- [23] L. P. Zhao, B. H. Li, and Y. Y. Yao, "A novel predict-prevention quality control method of multi-stage manufacturing process towards zero defect manufacturing," *Adv. Manuf.*, vol. 11, no. 2, 2023, doi: 10.1007/s40436-022-00427-9.
- [24] M. Papananias, T. E. McLeay, M. Mahfouf, and V. Kadirkamanathan, "A Bayesian information fusion approach for end product quality estimation using machine learning and on-machine probing," *J. Manuf. Process.*, vol. 76, 2022, doi: 10.1016/j.jmapro.2022.01.020.
- [25] C. Ruiz, D. Jafari, V. Venkata, T. H. J. Vaneker, W. Ya, and Q. Huang, "Prediction and Control of Product Shape Quality for Wire and Arc Additive Manufacturing," *J. Manuf. Sci. Eng.*, vol. 144, no. 11, 2022, doi: 10.1115/1.4054721.
- [26] C. H. Chien, P. Y. Chen, A. J. C. Trappey, and C. V. Trappey, "Intelligent Supply Chain Management Modules Enabling Advanced Manufacturing for the Electric-Mechanical Equipment Industry," *Complexity*, vol. 2022, 2022, doi: 10.1155/2022/8221706.
- [27] J. Gim and L. S. Turng, "A review of current advancements in high surface quality injection molding: Measurement, influencing factors, prediction, and control," *Polymer Testing*, 2022, doi: 10.1016/j.polymertesting.2022.107718.
- [28] N. Leberuyer, J. Bruch, M. Ahlskog, and S. Afshar, "Toward Zero Defect Manufacturing with the support of Artificial Intelligence—Insights from an industrial application," *Comput. Ind.*, vol. 147, 2023, doi: 10.1016/j.compind.2023.103877.
- [29] J. Takalo-Mattila, M. Heiskanen, V. Kyllonen, L. Maatta, and A. Bogdanoff, "Explainable Steel Quality Prediction System Based on Gradient Boosting Decision Trees," *IEEE Access*, vol. 10, 2022, doi: 10.1109/ACCESS.2022.3185607.
- [30] X. Li, Z. Huang, and W. Ning, "Intelligent manufacturing quality prediction model and evaluation system based on big data machine learning," *Comput. Electr. Eng.*, vol. 111, 2023, doi: 10.1016/j.compeleceng.2023.108904.
- [31] V. Azamfirei, F. Psarommatis, and Y. Lagrosen, "Application of automation for in-line quality inspection, a zero-defect manufacturing approach," *J. Manuf. Syst.*, 2023, doi: 10.1016/j.jmsy.2022.12.010.
- [32] S. Nannapaneni, S. Mahadevan, A. Dubey, and Y. T. T. Lee, "Online monitoring and control of a cyber-physical manufacturing process under uncertainty," *J. Intell. Manuf.*, vol. 32, no. 5, 2021, doi: 10.1007/s10845-020-01609-7.
- [33] M. Papananias, T. E. McLeay, M. Mahfouf, and V. Kadirkamanathan, "A probabilistic framework for product health monitoring in multistage manufacturing using Unsupervised Artificial Neural Networks and Gaussian Processes," *Proc. Inst. Mech. Eng. Part B J. Eng. Manuf.*, vol. 237, no. 9, 2023, doi: 10.1177/09544054221136510.