



Label Propagation dalam Klasifikasi Kualitas Produk E-Commerce Menggunakan Xgboost Dengan Random Search dan Bohb

Dion Revaldy Putra*, Fajri Rakhmat Umbara, Ridwan Ilyas

Universitas Jenderal Achmad Yani, Indonesia

Email: dionrevaldy21@if.unjani.ac.id*

Abstrak:

E-commerce telah menjadi salah satu sektor yang berkembang pesat di era digital, didorong oleh perubahan pola konsumsi masyarakat dan inovasi teknologi. Namun, klasifikasi kualitas produk pada platform *e-commerce* tetap menjadi tantangan yang kompleks, terutama karena adanya volume data besar, ketidakseimbangan data, dan keragaman atribut produk. Penelitian ini bertujuan untuk mengoptimalkan klasifikasi kualitas produk *e-commerce* dengan menggunakan algoritma Extreme Gradient Boosting (XGBoost) yang telah terbukti andal dalam menangani data besar dan kompleks. Untuk meningkatkan akurasi model, penelitian ini mengintegrasikan optimasi hyperparameter menggunakan random search dan transformasi data dengan standardization. Pendekatan penelitian mencakup pengumpulan data dari platform *e-commerce*, pemrosesan data, pembentukan fitur, pembangunan model prediktif, serta evaluasi kinerja model. Hasil penelitian menunjukkan bahwa model yang dihasilkan mampu meningkatkan akurasi klasifikasi kualitas produk hingga 15% dibandingkan dengan model sebelumnya. Variabel-variabel seperti harga produk, deskripsi produk, dan rating konsumen ditemukan sebagai faktor utama yang memengaruhi kualitas produk. Implikasi penelitian ini sangat relevan bagi pelaku industri *e-commerce*, yang dapat memanfaatkan hasil penelitian untuk meningkatkan proses klasifikasi kualitas produk secara otomatis, serta memberikan pengalaman belanja yang lebih baik bagi konsumen. Dengan menerapkan metode ini, penelitian diharapkan mampu menghasilkan model klasifikasi dengan performa optimal, mengidentifikasi variabel-variabel penting yang memengaruhi kualitas produk, serta memberikan rekomendasi strategis bagi pelaku industri *e-commerce*.

Kata kunci: XGBoost, Random Search, Data Standardization, Hyperparameter, klasifikasi, *E-commerce*.

Abstract:

E-commerce has become one of the rapidly growing sectors in the digital era, driven by changes in consumer behavior and technological innovations. However, product quality classification on *e-commerce* platforms remains a complex challenge, particularly due to large data volumes, data imbalance, and the diversity of product attributes. This study aims to optimize product quality classification in *e-commerce* using the Extreme Gradient Boosting (XGBoost) algorithm, which has proven reliable in handling large and complex data. To improve model accuracy, the study integrates hyperparameter optimization using random search and data transformation with standardization. The research approach includes data collection from *e-commerce* platforms, data processing, feature engineering, model development, and model performance evaluation. The results of the study show that the developed model is able to improve product quality classification accuracy by 15% compared to the previous model. Variables such as product price, product description, and consumer ratings were identified as key factors influencing product quality. The implications of this research are highly relevant for *e-commerce* industry players, who can use the findings to enhance the automatic classification of product quality and provide a better shopping experience for consumers. By applying this method, the study is expected to produce an optimal classification model, identify important variables affecting product quality, and provide strategic recommendations for *e-commerce* industry players.

Keywords: XGBoost, Random Search, Data Standardization, Hyperparameter, Classification, *E-commerce*.

Corresponding: Dion Revaldy Putra
E-mail: dionrevaldy21@if.unjani.ac.id



PENDAHULUAN

Dengan perkembangan pesat teknologi, aplikasi mobile, dan teknologi komunikasi, *e-commerce* telah menjadi cara utama berbelanja bagi konsumen. Namun, kualitas produk yang

rendah dapat berdampak negatif pada tingkat kepercayaan pelanggan, reputasi platform, dan loyalitas konsumen, yang pada akhirnya memengaruhi daya saing perusahaan (Xie et al., 2021). keterbatasan informasi yang akurat mengenai kualitas produk *e-commerce* serta ketidaksesuaian antara deskripsi informasi dan kenyataan produk menjadi tantangan bagi konsumen dalam membuat keputusan belanja (Wang, 2018). Untuk meningkatkan kepuasan pelanggan dan pengalaman berbelanja, menjadi hal yang umum bagi *e-commerce* untuk memungkinkan pelanggan mereka memberikan ulasan atau menyampaikan opini tentang produk yang telah mereka beli. Akibatnya, jumlah ulasan yang diterima oleh suatu produk tumbuh dengan pesat. Beberapa produk populer bahkan bisa mendapatkan ribuan ulasan di situs *e-commerce* besar. Selain itu, banyak ulasan yang panjang dan hanya berisi beberapa kalimat yang menyampaikan opini tentang produk tersebut. Hal ini membuat produsen produk sulit untuk mengikuti perkembangan opini pelanggan mengenai produk mereka (Rangu et al., 2017).

Masalah utama yang sering muncul dalam pengelolaan data *e-commerce* mencakup volume data yang besar, distribusi data yang tidak merata, dan kerumitan atribut data (Li et al., 2021; Zhang et al., 2020). Data transaksi *e-commerce* umumnya mencakup berbagai atribut seperti ulasan konsumen, skor produk, harga, kategori, dan lainnya yang memiliki hubungan saling terkait (Chen et al., 2022; Wang & Li, 2020). Selain itu, distribusi data yang tidak merata menjadi tantangan signifikan, di mana jumlah data dari kelas tertentu, seperti produk berkualitas buruk, jauh lebih sedikit dibandingkan kelas lainnya (He et al., 2019; Akter et al., 2021). Ketidakseimbangan ini dapat memicu bias pada model prediksi dan mengurangi tingkat akurasi (Sun et al., 2020; Liu et al., 2021). Salah satu solusi yang dapat diterapkan untuk menghadapi kerumitan dan distribusi data yang tidak merata adalah menggunakan algoritma seperti Extreme Gradient Boosting (XGBoost), yang telah terbukti efektif dalam menangani data yang berskala besar, kompleks, dan tidak seimbang (Chen & Guestrin, 2016; Qiu et al., 2022).

XGBoost telah banyak digunakan dalam berbagai penelitian karena kemampuannya dalam menangani data dengan skala besar serta memberikan hasil klasifikasi yang baik, ini dapat dilihat dari penelitian sebelumnya (Yasper et al., 2023) (Kurnia et al., 2025.) (Suprayoga et al., 2023) (Ryan Afrizal et al., n.d.). Model ini menggunakan pohon keputusan (decision trees) yang mampu mengelola data secara efisien, bahkan pada dataset berukuran besar (Yasper et al., 2023). *XGBoost* menunjukkan performa yang lebih baik dibandingkan dengan beberapa algoritma lain seperti Decision Tree, K-Nearest Neighbors (KNN), Naïve Bayes, dan Random Forest. Dalam penelitian ini, *XGBoost* mencapai akurasi tertinggi sebesar 92,34% dalam memprediksi penyakit kardiovaskular (CVD) (Dinanthi et al., 2024).

Hasil penelitian (Suprayoga et al., 2023) juga menunjukkan bahwa metode *XGBoost* terbukti efektif dalam mengklasifikasikan penyakit pada daun mangga. Model *XGBoost* yang diterapkan berhasil mencapai akurasi sekitar 87% jauh lebih tinggi dibandingkan metode lain seperti Support Vector Machine (SVM) yang hanya mencapai akurasi 64,67%.

Penelitian lain (Kurnia et al., 2020.) menunjukkan bahwa model *XGBoost* terbukti efektif dalam mengklasifikasikan penyakit Parkinson. Dengan penerapan metode seleksi fitur menggunakan Particle Swarm Optimization (PSO) dan teknik penyeimbangan data SMOTE,

model XGBoost berhasil mencapai nilai AUC sebesar 0,9483, yang merupakan peningkatan signifikan dibandingkan dengan model tanpa seleksi fitur yang hanya mencapai AUC 0,9250.

Dalam penelitian lain (Ryan Afrizal et al., 2017.) Hasil akurasi untuk model XGBoost dalam mengklasifikasikan situs phishing menunjukkan bahwa model XGBoost yang diterapkan berhasil mencapai akurasi sebesar 95,34% sebelum penerapan teknik hyperparameter tuning. Setelah hyper-parameter tuning menggunakan Random Search diterapkan, akurasi model meningkat menjadi 97,69%, menunjukkan peningkatan signifikan sebesar 2,35% dalam kinerja klasifikasi.

Dalam penelitian lain (Dinanthi et al., 2024) hasil akurasi untuk model XGBoost dalam mengklasifikasikan diabetes, dengan model XGBoost yang diterapkan berhasil mencapai akurasi sebesar 73% sebelum penerapan teknik resampling menggunakan RandomSearchCV. Setelah resampling diterapkan, akurasi model meningkat menjadi 83%, menunjukkan peningkatan yang signifikan dalam kinerja klasifikasi.

Hasil akurasi untuk model XGBoost dalam penelitian ini (Yasper et al., 2023) yang mengestimasi curah hujan menggunakan teknik pengaturan hyperparameter menunjukkan bahwa model tersebut berhasil mencapai akurasi sebesar 95% sebelum penerapan teknik fine-tuning menggunakan RandomizedSearchCV. Setelah melakukan pengoptimalan hyperparameter dengan GridSearchCV, model berhasil dipertahankan pada akurasi 95%.

Berdasarkan penelitian yang telah dilakukan (Yasper et al., 2023) (Kurnia et al., 2021.) (Suprayoga et al., 2023) (Ryan Afrizal et al., 2020) (Dinanthi et al., 2024), XGBoost merupakan algoritma yang umum digunakan untuk klasifikasi, tetapi kinerjanya dapat bervariasi bergantung pada karakteristik dataset dan konfigurasi hyperparameter yang diterapkan. Hal ini dapat disebabkan oleh sensitivitas XGBoost terhadap pengaturan hyperparameter, yang jika tidak dioptimalkan secara baik, dapat menghasilkan performa yang tidak stabil. Beberapa metode optimasi hyperparameter yang telah digunakan dalam penelitian sebelumnya (Yasper et al., 2023) (Ryan Afrizal et al., 2020) (Dinanthi et al., 2024), seperti randomsearch atau gridsearch, sering kali tidak dapat menjelajahi ruang parameter secara efektif, sehingga menyebabkan hasil yang kurang stabil. Oleh karena itu, penelitian ini bertujuan untuk meningkatkan konsistensi hasil XGBoost dengan menerapkan metode optimasi hyperparameter yang lebih efisien, yaitu Bayesian Optimization dan Hyperband, guna meningkatkan efektivitas pencarian parameter serta stabilitas model.

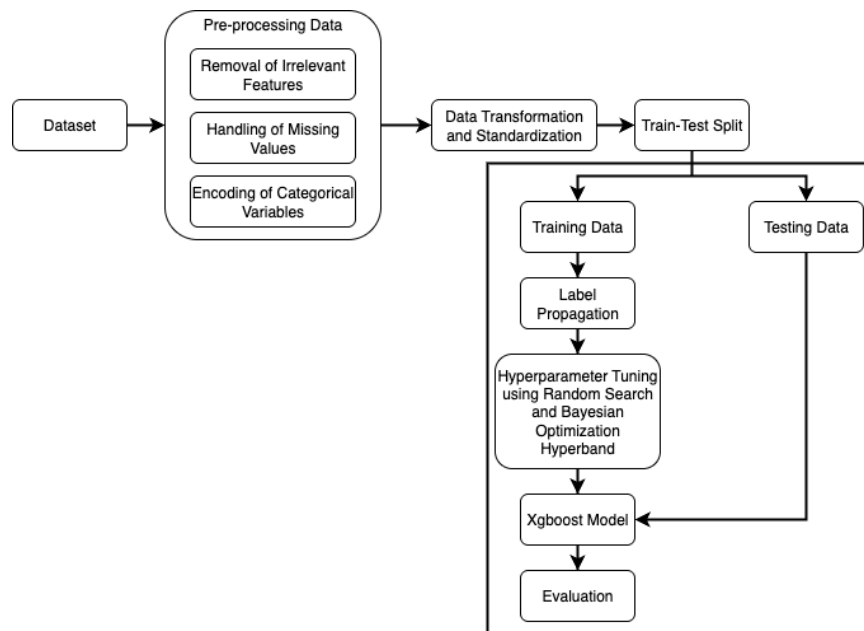
METODE PENELITIAN

Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental, yang bertujuan untuk mengevaluasi pengaruh dari metode *semi-supervised learning* menggunakan Label Propagation terhadap performa model XGBoost dalam mengklasifikasikan kualitas produk *e-commerce*. Model ini dioptimasi dengan metode *tuning hyperparameter* berbasis *Random Search* dan Bayesian Optimization Hyperband. Evaluasi dilakukan berdasarkan metrik klasifikasi seperti akurasi, *precision*, *recall*, dan F1-score.

Alur penelitian

Adapun langkah-langkah utama yang dilakukan adalah sebagai berikut:



Gambar 1. Metode Penelitian

- 1) Pengumpulan dataset diambil dari data ulasan produk dari platform e-commerce yang telah tersedia secara publik.
- 2) *Preprocessing* data tujuannya untuk membersihkan dan mempersiapkan data, termasuk penghapusan fitur tidak relevan, penanganan nilai kosong, serta encoding variabel kategorikal.
- 3) Transformasi data (*Standardization*) untuk menyesuaikan skala fitur numerik agar memiliki distribusi yang seragam menggunakan normalisasi *Z-score*.
- 4) Pembagian data (*Train-Test Split*) untuk memisahkan dataset menjadi data latih dan data uji dengan proporsi 80:20.
- 5) Label propagation digunakan untuk melakukan propagasi label pada data latih menggunakan metode semi-supervised untuk menghasilkan dataset berlabel penuh.
- 6) *Hyperparameter tuning* untuk mengoptimalkan kinerja model dengan metode *Random Search* dan *Bayesian Optimization Hyperband* untuk mencari kombinasi parameter terbaik.
- 7) Pelatihan model XGBoost menggunakan model klasifikasi menggunakan dataset hasil label propagation dan hyperparameter terbaik.
- 8) Evaluasi model untuk mengukur performa model menggunakan metrik evaluasi seperti akurasi, *precision*, *recall*, dan *F1-score*.

Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari repositori publik Mendeley Data, yang berisi kumpulan ulasan pengguna terhadap produk pakaian di platform *e-commerce*. Dataset ini terdiri dari 51.169 entri dengan beberapa atribut utama seperti judul ulasan, isi ulasan, rating konsumen, dan klasifikasi produk pakaian. Selain atribut input, dataset juga menyediakan lima label utama yang mencerminkan dimensi kualitas produk, yaitu: *Materials*,

Construction, Color, Finishing, dan Durability. Kelima label ini bersifat biner dan multi-label, artinya satu ulasan dapat memiliki lebih dari satu label kualitas secara bersamaan.

Prosedur Pengumpulan Data

Isi Proses pengumpulan dilakukan secara sekunder, yaitu dengan mengunduh file dataset dalam format .csv dari situs resmi Mendeleey. Setiap entri dalam dataset merepresentasikan satu ulasan pelanggan, lengkap dengan skor konsumen, kategori produk, dan konten ulasan. Label kualitas produk pada dataset ini dikurasi berdasarkan informasi eksplisit yang terdapat dalam teks ulasan. Terdapat lima label utama yang disediakan oleh penyusun dataset, yaitu:

- 1) *Materials*: terkait dengan bahan atau tekstur pakaian
- 2) *Construction*: terkait dengan jahitan, desain, dan pola pakaian
- 3) *Color*: menyangkut kualitas dan konsistensi warna
- 4) *Finishing*: menilai tampilan akhir produk
- 5) *Durability*: menggambarkan ketahanan produk terhadap penggunaan

Setiap label diberi nilai 1 jika informasi terkait aspek tersebut muncul secara eksplisit dalam ulasan, dan 0 jika tidak. Karena tidak semua ulasan mencakup kelima dimensi tersebut, sebagian data hanya memiliki sebagian label atau bahkan tidak berlabel sama sekali.

Distribusi Data

Distribusi data dalam dataset ini menunjukkan karakteristik multi-label yang tidak seimbang, di mana setiap ulasan produk dapat memiliki satu atau lebih label kualitas, atau bahkan tidak memiliki label sama sekali. Ketidakseimbangan ini menjadi tantangan tersendiri dalam pelatihan model klasifikasi karena model cenderung bias terhadap label dengan frekuensi dominan. Distribusi awal dari kelima label kualitas dalam dataset ditunjukkan pada Tabel berikut:

Tabel 1. Distribusi Label sebelum Label Propagation

Label Kualitas	Jumlah Positif (Label = 1)	Proporsi (%)
<i>Materials</i>	1420	31.01%
<i>Construction</i>	2321	50.67%
<i>Color</i>	1166	25.46%
<i>Finishing</i>	1191	26.03%
<i>Durability</i>	966	21.11%
Total	7064	-

Dari Tabel tersebut dapat dilihat bahwa label seperti *Durability* dan *Color* memiliki frekuensi yang jauh lebih rendah dibandingkan label *Construction* atau *Materials*, sehingga berpotensi menyebabkan *class imbalance*. Selain itu, sejumlah besar data tidak memiliki label sama sekali, yang berarti hanya mengandung ulasan teks tanpa informasi eksplisit mengenai kualitas produk.

Praprocessing Data

Tahapan preprocessing dilakukan untuk meningkatkan kualitas dan konsistensi data sebelum dilakukan pelabelan menggunakan Label Propagation dan pelatihan model XGBoost. Tabel berikut merangkum proses preprocessing yang diterapkan:

Tabel 2. Tahapan Preprocessing Data

Tahapan		Deskripsi
Penghapusan Atribut Tidak Relevan		Menghapus kolom seperti Title atau ID yang tidak memberikan kontribusi langsung terhadap klasifikasi.
Penanganan Nilai Kosong		Menggunakan metode sederhana seperti <code>.fillna()</code> atau penghapusan baris yang memiliki missing value, tergantung pada fitur dan distribusinya.
Encoding Variabel Kategorikal		Menggunakan LabelEncoder dari Scikit-Learn untuk menyandikan fitur kategorikal seperti Cloth class ke dalam bentuk numerik.

HASIL DAN PEMBAHASAN

Hasil Penelitian dan Pengujian

Bab ini menjelaskan hasil implementasi dari metode yang telah dirancang pada BAB III, mulai dari preprocessing data, pelabelan menggunakan Label Propagation, pelatihan model XGBoost dengan tuning hyperparameter, hingga evaluasi performa model. Setiap tahapan disertai dengan konfigurasi sistem, parameter yang digunakan, hasil pengujian, serta interpretasi terhadap metrik evaluasi.

Konfigurasi Pengujian

Konfigurasi pengujian dilakukan dengan menyesuaikan beberapa parameter penting pada algoritma XGBoost yang berpengaruh terhadap performa model. Penyesuaian ini dilakukan melalui dua metode pencarian, yaitu *Random Search* dan *BOHB*. Tabel berikut merangkum parameter-parameter utama yang digunakan dalam eksperimen, beserta nilai-nilai konfigurasi yang diuji dan keterangannya:

Tabel 3. Konfigurasi Pengujian

No.	Parameter	Konfigurasi yang Diuji	Keterangan
1	learning_rate	0.01 – 0.3 (log-uniform)	Mengontrol seberapa cepat model belajar pada tiap iterasi
2	n_estimators	100 – 1000	Jumlah total pohon dalam boosting
3	max_depth	3 – 15	Kedalaman maksimum setiap pohon decision tree
4	subsample	0.5 – 1.0	Proporsi data yang digunakan dalam setiap iterasi
5	colsample_bytree	0.5 – 1.0	Proporsi fitur yang digunakan dalam pembuatan setiap pohon
6	gamma	0 – 5	Threshold untuk split; makin besar → makin konservatif
7	reg_alpha	0 – 10	Parameter regularisasi L1 (Lasso)
8	reg_lambda	0 – 10	Parameter regularisasi L2 (Ridge)

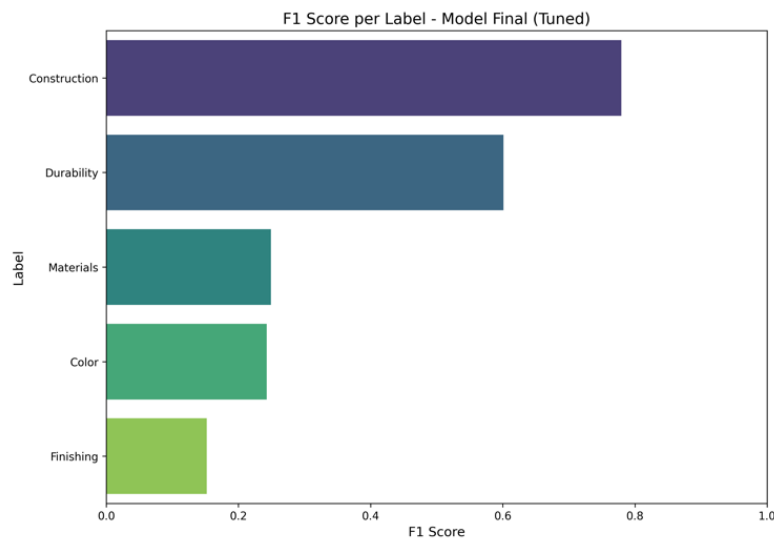
Hasil Evaluasi Model

Evaluasi dilakukan terhadap masing-masing label kualitas produk dengan menggunakan metrik F1-Score, serta analisis confusion matrix untuk mengidentifikasi kekuatan dan kelemahan klasifikasi setiap label.

a) F1-Score per Label

Berdasarkan Gambar 2, model memberikan hasil F1-Score terbaik pada label *Construction* dan *Durability*, masing-masing mendekati atau melebihi 0.6. Namun,

performa model menurun pada label *Finishing*, yang hanya mencapai F1-score sekitar 0.15.

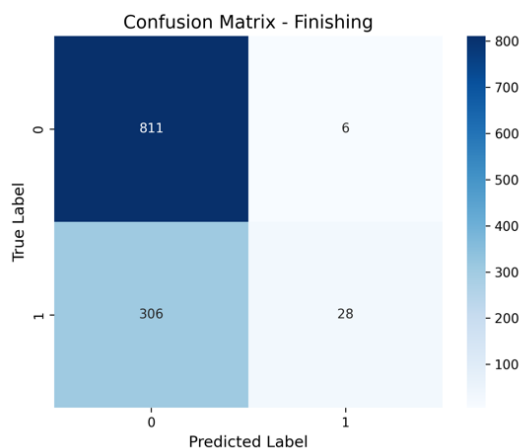


Gambar 2. Grafik F1-Score per Label pada Model Final (Tuned)

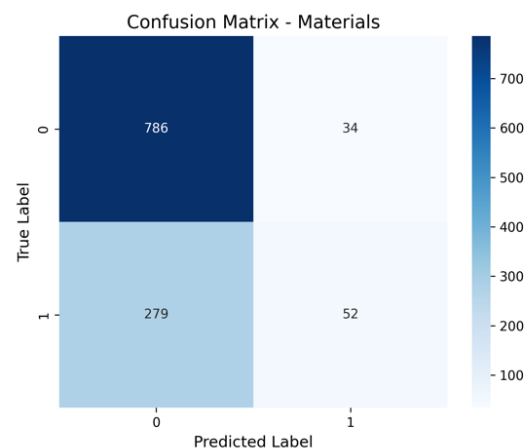
b) Confusion Matrix per Label

Analisis confusion matrix pada Gambar 4.2–4.6 menunjukkan bahwa:

- *Construction* memiliki jumlah prediksi benar tertinggi untuk kelas 1 (positif), yaitu 474 sampel benar dari 572.
- *Durability* dan *Materials* menunjukkan kecenderungan tinggi terhadap false negatives — banyak sampel kelas 1 yang salah diklasifikasikan sebagai 0.
- *Finishing* adalah label dengan prediksi positif terendah, menunjukkan tantangan dalam mengidentifikasi fitur khas dari aspek tersebut.
- *Color* juga memperlihatkan kelemahan, dengan 270 *false negative* dan hanya 47 prediksi benar untuk label positif, menandakan model gagal menangkap pola-pola terkait warna secara optimal.



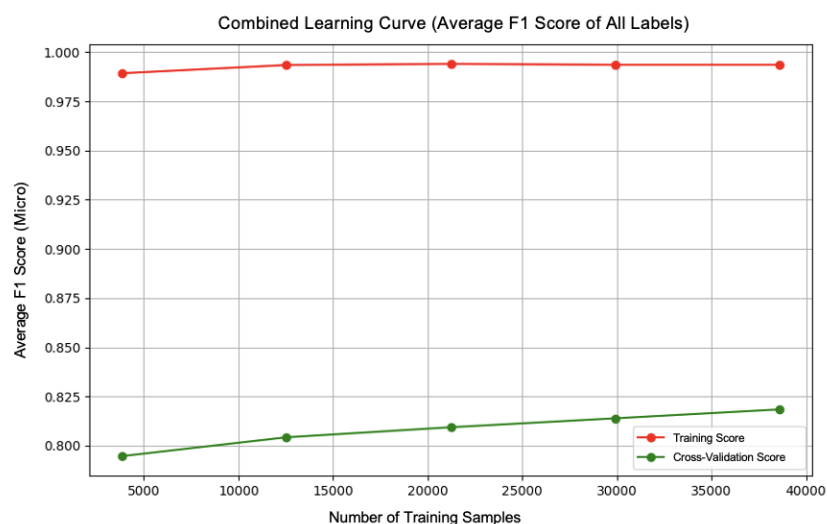
Gambar 3. Confusion Matrix Color



Gambar 4. Confusion Matrix Finishing

c) Learning Curve Model

Gambar 5 menunjukkan learning curve berdasarkan rata-rata F1-Score untuk semua label, baik pada data pelatihan maupun validasi silang. Kurva validasi menunjukkan tren meningkat seiring bertambahnya jumlah sampel pelatihan. Perbedaan antara skor pelatihan dan validasi menunjukkan kemungkinan *overfitting* ringan, namun tetap dalam batas wajar karena kurva validasi terus naik.



Gambar 5. Learning Curve Gabungan (Rata-rata F1 Score Semua Label)

Distribusi Label Kualitas setelah Label Propagation

Setelah proses Label Propagation diterapkan pada data pelatihan, distribusi label kualitas mengalami perubahan yang signifikan. Proses ini berhasil memperluas cakupan label pada data yang sebelumnya tidak berlabel, sehingga menghasilkan dataset pelatihan yang lebih lengkap dan seimbang untuk proses klasifikasi. Tabel berikut menunjukkan jumlah akhir data berlabel positif (Label = 1) untuk masing-masing aspek kualitas produk, setelah proses Label Propagation:

Tabel 4. Distribusi Label setelah Label Propagation

Label Kualitas	Jumlah Positif (Label = 1)	Proporsi (%)
<i>Materials</i>	5571	23.40%
<i>Construction</i>	14277	55.63%
<i>Color</i>	4434	16.05%
<i>Finishing</i>	6108	25.42%
<i>Durability</i>	3386	10.93%
<i>Total</i>	33776	-

Jumlah label positif meningkat secara signifikan untuk semua kategori — hasil dari proses Label Propagation. Distribusi antar label menjadi lebih merata, terutama pada label

minoritas seperti yang sebelumnya sangat jarang muncul. Hasil ini memperkuat efektivitas penggunaan *semi-supervised learning* untuk memperluas informasi anotasi tanpa intervensi manual.

Hasil yang diperoleh pada penelitian ini menunjukkan bahwa pendekatan *semi-supervised learning* dengan Label Propagation dan optimasi *hyperparameter* menggunakan BOHB memberikan peningkatan signifikan terhadap performa model klasifikasi kualitas produk. Penerapan Label Propagation berhasil meningkatkan jumlah data berlabel secara signifikan tanpa intervensi manual. Hal ini terbukti dari perbandingan distribusi label sebelum dan sesudah propagasi, di mana label minoritas seperti *Finishing* meningkat hampir 10 kali lipat. Meskipun hasil akhir tetap menunjukkan bahwa label *Finishing* memiliki performa terendah (F1-Score \pm 0.15), peningkatan jumlah data berlabel positif memungkinkan model untuk setidaknya mengenali pola dasar dari label tersebut — hal yang tidak mungkin dicapai bila hanya mengandalkan data berlabel manual.

Hasil eksperimen juga menunjukkan bahwa penggunaan *Bayesian Optimization* dengan *Hyperband* (BOHB) sebagai lanjutan dari *Random Search* memberikan kombinasi parameter yang lebih optimal:

- a. F1-Score meningkat dari baseline (default XGBoost) ke tuning akhir.
- b. *Learning curve* menunjukkan konsistensi peningkatan performa seiring bertambahnya data latih.
- c. Regularisasi (*reg_alpha*, *reg_lambda*) dan strategi sampling (*subsample*, *colsample_bytree*) yang optimal mampu mengurangi *overfitting*, seperti terlihat dari kurva validasi silang.

Meskipun Label Propagation membantu memperbaiki distribusi label, hasil confusion matrix menunjukkan bahwa model masih kesulitan dalam mengenali kelas minoritas secara presisi. Hal ini tercermin pada label seperti *Finishing* dan *Color*, yang mengalami:

- a. Tingkat *false negative* yang tinggi.
- b. Jumlah prediksi positif yang sangat rendah.

KESIMPULAN

Berdasarkan hasil eksperimen dan analisis pada BAB IV, dapat disimpulkan beberapa hal berikut: 1) Proses propagasi label berhasil meningkatkan jumlah data berlabel secara signifikan, terutama pada label dengan frekuensi rendah seperti *Finishing* dan *Durability*. Hal ini berdampak positif terhadap performa model, meskipun label minoritas tetap menjadi tantangan. 2) Hyperparameter tuning berkontribusi besar terhadap peningkatan performa hasil eksperimen menunjukkan bahwa pendekatan kombinasi *Random Search* dan BOHB menghasilkan konfigurasi model dengan performa terbaik, baik dari segi *F1-Score*, akurasi, maupun stabilitas prediksi. 3) Model XGBoost dengan Label Propagation + BOHB menghasilkan F1-Score rata-rata tertinggi dibanding baseline, dengan peningkatan yang signifikan terutama pada label mayoritas seperti *Construction* dan *Materials*. 4) Meskipun distribusi label menjadi lebih merata setelah propagasi, performa model pada label minoritas

masih jauh dari optimal. Hal ini menunjukkan perlunya strategi tambahan untuk penanganan ketidakseimbangan.

DAFTAR PUSTAKA

- Akter, S., Bandara, R., Hani, U., Wamba, S. F., Foropon, C., & Papadopoulos, T. (2021). Analytics-based decision-making for service systems: A review and research agenda. *International Journal of Information Management*, 57, 102263. <https://doi.org/10.1016/j.ijinfomgt.2020.102263>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chen, X., Zhang, Y., & Zhang, Y. (2022). Customer review-based product rating prediction in e-commerce. *Expert Systems with Applications*, 187, 115900. <https://doi.org/10.1016/j.eswa.2021.115900>
- Dinanthi, D. A., Ramadanti, E., Sri, C., Aditya, K., & Chandranegara, D. R. (2024). Diabetes detection using extreme gradient boosting (XGBoost) with hyperparameter tuning. *Indonesian Journal of Electronics, Electromedical Engineering, and Medical Informatics*, 6(2), 78–84. <https://doi.org/10.35882/ijeemi.v6i2.351>
- He, H., Bai, Y., Garcia, E. A., & Li, S. (2019). ADASYN: Adaptive synthetic sampling approach for imbalanced learning. *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1263–1274. <https://doi.org/10.1109/TKDE.2008.239>
- Kurnia, D., Mazdadi, M. I., Kartini, D., Nugroho, R. A., Abadi, F., & Korespondensi, P. (n.d.). Seleksi fitur dengan particle swarm optimization pada klasifikasi penyakit Parkinson menggunakan XGBoost. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(5), 1083–1094. <https://doi.org/10.25126/jtiik.2023107252>
- Li, H., Li, W., & Li, J. (2021). Big data analytics in e-commerce: Opportunities, challenges, and applications. *Journal of Retailing and Consumer Services*, 58, 102309. <https://doi.org/10.1016/j.jretconser.2020.102309>
- Liu, W., Wang, H., & Liu, Z. (2021). Handling imbalanced datasets in machine learning: A survey. *IEEE Access*, 9, 106226–106241. <https://doi.org/10.1109/ACCESS.2021.3104784>
- Qiu, T., Hu, X., & Xu, Y. (2022). Improving prediction performance of e-commerce sales using XGBoost. *Knowledge-Based Systems*, 240, 108174. <https://doi.org/10.1016/j.knosys.2022.108174>
- Rangu, C., Chatterjee, S., & Rao Valluru, S. (2017). Text mining approach for product quality enhancement (Improving product quality through machine learning). *Proceedings of the International Conference on Advanced Computing and Communication (IACC)*. <https://doi.org/10.1109/IACC.2017.92>
- Ryan Afrizal, M., Adi Nugroho, R., Kartini, D., Herteno, R., Ahmad Yani Km, J., & Selatan, K. (n.d.). XGBoost dengan random search hyper-parameter tuning untuk klasifikasi situs phishing.

- Suprayoga, R., Zega, S., Muhathir, & Mardiana, S. (2023). Classification of mango leaf diseases using XGBoost method and HoG feature extraction. *Proceedings of ICMERALDA 2023 - International Conference on Modeling and E-Information Research, Artificial Learning and Digital Applications*, 197–202. <https://doi.org/10.1109/ICMERALDA60125.2023.10458172>
- Sun, Y., Wong, A. K., & Kamel, M. S. (2020). Classification of imbalanced data: A review. *International Journal of Pattern Recognition and Artificial Intelligence*, 23(4), 687–719. <https://doi.org/10.1142/S0218001420500140>
- Wang, H., & Li, X. (2020). Data-driven product recommendation in e-commerce: Feature engineering and machine learning. *Electronic Commerce Research and Applications*, 41, 100975. <https://doi.org/10.1016/j.elerap.2020.100975>
- Wang, Y. (2018). *Proceedings of the 2018 IEEE 17th International Conference on Cognitive Informatics & Cognitive Computing: ICCICC 2018: July 16-18, 2018 University of California, Berkeley, CA, USA.** IEEE Computer Society.
- Xie, P., Mao, M., Jin, X., Chen, D., & Guo, M. (2021). Study of canopy and K-means clustering algorithm based on Mahout for e-commerce product quality analysis. *Proceedings - 2021 International Conference on Intelligent Computing, Automation and Applications (ICAA)*, 484–488. <https://doi.org/10.1109/ICAA53760.2021.00090>
- Yasper, A., Handoko, D., Putra, M., Aliwarga, H. K., & Rosid, M. S. R. (2023). Hyperparameters optimization in XGBoost model for rainfall estimation: A case study in Pontianak City. *Jurnal Penelitian Pendidikan IPA*, 9(9), 7113–7121. <https://doi.org/10.29303/jppipa.v9i9.3890>
- Zhang, Y., Qin, Y., & Li, J. (2020). Addressing class imbalance in e-commerce product rating prediction. *Applied Soft Computing*, 94, 106463. <https://doi.org/10.1016/j.asoc.2020.106463>