

Rekomendasi Produk *E-commerce* Berbasis Klasifikasi Ulasan Menggunakan *Ensemble Random Forest* dan Teknik *Boosting*

Donny Saputro^{1*}, Danang Wahyu Utomo²

^{1, 2}Program Studi Teknik Informatika, Universitas Dian Nuswantoro

^{1, 2}Jln Imam Bonjol No.207 Pendrikan Kidul, Kecamatan Semarang Tengah, 50131, Indonesia

E-mail: 111202012396@mhs.dinus.ac.id¹, danang.wu@dsn.dinus.ac.id²

Info Naskah:

Naskah masuk: 22 Mei 2024

Direvisi: 25 Juni 2024

Diterima: 4 Juli 2024

Abstrak

Meningkatnya popularitas e-commerce menjadi tantangan baru untuk memberikan pengalaman berbelanja pelanggan yang lebih personal dan efektif. Dalam situasi seperti ini, rekomendasi produk sangat penting untuk meningkatkan kepuasan konsumen dan meningkatkan penjualan. Dengan menggunakan teknik ensemble Random Forest dan Boosting, penelitian ini memperkenalkan metode untuk rekomendasi produk e-commerce berdasarkan analisis ulasan pengguna. Tujuannya untuk menguji algoritma *Random Forest* dengan beberapa teknik boosting untuk pembelajaran *ensemble*. Hasil uji menunjukkan bahwa metode Random Forest dengan kombinasi teknik Xgboost dapat memberikan rekomendasi produk yang lebih akurat yaitu sebesar 87.25% dan relevan dari pada teknik boosting lain. Pada analisis presisi, Random Forest-Xgboost menghasilkan akurasi lebih tinggi yaitu 90%. Dibandingkan Teknik boosting lainnya, hal ini membuktikan bahwa teknik tersebut mampu memprediksi secara akurat kelas positif. Berdasarkan hasil uji, kombinasi teknik Boosting dan Random Forest dapat meningkatkan kinerja model dalam menangani kompleksitas dan variasi dalam ulasan produk e-commerce.

Keywords:

recommendations;
e-commerce;
ensemble learning;
random forest;
boosting;

Abstract

The increasing popularity of e-commerce poses a new challenge to provide customers with a more personalized and effective shopping experience. In situations like this, product recommendations are very important to increase consumer satisfaction and increase sales. Using Random Forest and Boosting ensemble techniques, this research introduces a method for e-commerce product recommendation based on user review analysis. The Aim is to test the Random Forest algorithm with several boosting techniques for ensemble learning. The results show that the Random Forest method combined with the Xgboost technique can provide product recommendations that are 87.25% more accurate and relevant than other boosting techniques. In precision analysis, Random Forest-XGBoost achieved a higher accuracy of 90% compared to other boosting techniques. Additionally, the combined use of Boosting and Random Forest techniques improves the model's performance in handling complexity and variation in e-commerce product reviews.

*Penulis korespondensi:

Donny Saputro

E-mail: 111202012396@mhs.dinus.ac.id

1. Pendahuluan

Pada era digital saat ini perkembangan dalam dunia *e-commerce* sangat pesat, media sosial telah memberi peluang bisnis dan organisasi untuk berkesempatan mendapatkan umpan balik dari pelanggan dan klien melalui ulasan yang dibuat oleh pengguna pada postingan *e-commerce* mereka. Sebagian pelanggan sudah menggunakan aplikasi untuk berbelanja berbagai kebutuhan. Banyak perusahaan dan organisasi yang membuat website ataupun aplikasi *e-commerce* untuk mempermudah proses transaksi. Selain dipermudah jangkauan pemasaran, juga semakin luas karena adanya akses internet. Belanja online juga sangat populer diseluruh dunia. Sekitar 2 miliar orang membeli barang sehari hari melalui situs belanja online. Pelanggan biasanya memutuskan untuk membeli barang berdasarkan ulasan yang memungkinkan atau meyakinkan mereka untuk menemukan produk yang lebih baik. Karena kemajuan *e-commerce* kehidupan modern menjadi lebih nyaman. Orang - orang dapat dengan mudah mendapatkan berbagai barang yang dibutuhkan secara online tanpa harus berkunjung ke toko [1]. Tokopedia menawarkan berbagai macam produk, dan setiap produk memiliki ulasan. Ulasan produk adalah cara yang sering digunakan untuk mendapatkan informasi dan merangkum kualitas produk [2].

Dengan berkembangnya platform *e-commerce*, ulasan produk menjadi sumber informasi penting bagi pelanggan. Analisis sentimen terhadap ulasan produk menjadi sangat penting karena dapat memberikan wawasan tentang pendapat pelanggan mengenai berbagai produk dan layanan [3]. Umpan balik, ulasan atau komentar terhadap suatu produk berguna untuk mengetahui kualitas produk dan meningkatkan nilai dari produk tersebut [4]. Untuk saat ini, hanya ada beberapa program yang dapat melakukan analisis sentimen data teks media sosial. Ini karena struktur teks media sosial yang tidak teratur membuatnya sulit untuk mengidentifikasi karakteristik fase representasi teks yang tepat [5]. Mengidentifikasi sentimen dapat menjadi penting bagi pengambil keputusan individu, organisasi bisnis, dan pemerintah. Mengidentifikasi perspektif publik tentang kebijakan, barang, dan organisasi dapat menguntungkan individu, sistem pendukung keputusan, dan organisasi. Metode analisis sentimen secara umum dibagi menjadi dua kelompok, yaitu metode berbasis leksikon dan metode berbasis pembelajaran mesin. Metode berbasis leksikon mengidentifikasi orientasi sudut pandang publik tentang kebijakan, barang, dan organisasi. Metode berbasis pembelajaran mesin menggunakan kumpulan data berlabel sebagai kumpulan pelatihan untuk membangun model klasifikasi dengan menggunakan pembelajar yang diawasi. Algoritma seperti *Random Forest*, *Naive Bayes*, *support vector machine*, dan algoritma digunakan sebagai pembelajar yang diawasi [6].

Analisis sentimen biasanya diterapkan pada data tekstual untuk membantu perusahaan memantau wawasan merek dan produk dari umpan balik pelanggan dan memahami kebutuhan pelanggan, sehingga dapat membantu pelanggan dan organisasi mencapai tujuannya. Memang, *e-commerce* menghadapi tantangan besar untuk mengetahui preferensi pelanggan, yaitu produk yang akan mereka sarankan. Berikut merupakan beberapa solusi yang telah

diusulkan, analisis sentimen ulasan produk konsumen Indonesia dengan gabungan *leksikon sentimen*, *N-gram*, dan penyematan kata *BERT* [5], metode *Random Forest* [2], *Multinomial Naive Bayes classifier* [7], *K-NN*, *Support vector machine* [8], algoritma *xgboost* [9]. Masing – masing algoritma mampu bekerja dengan baik sesuai dengan tujuan fokus pada analisis sentimen ulasan produk. Beberapa penelitian menggunakan algoritma Tunggal atau individu dalam analisis sentimen ulasan produk. Kekurangan dari algoritma Tunggal dapat memberikan performa yang kurang baik dalam analisis sentimen ulasan.

Pada penelitian ini penulis mengusulkan penggabungan (ensemble) *Random Forest* dengan teknik *boosting*. Algoritma *Random Forest* mampu mengklasifikasikan data dengan jumlah yang besar, Penggunaan pohon yang lebih banyak akan menghasilkan akurasi yang lebih baik. Teknik pembelajaran ensemble diusulkan untuk mendapatkan pohon terbaik dibandingkan dengan algoritma tunggal yaitu *random forest* sendiri. Pada eksperimen, Algoritma *Random Forest* digabungkan dalam pembelajaran ensemble dengan teknik *boosting* untuk melatih model – model dengan performa rendah. Tujuannya untuk mendapatkan performa lebih baik. Uji coba dilakukan terhadap beberapa algoritma seperti *xgboost*, *gradient boosting* dan *light gradient boosting* untuk mengetahui performa terbaik dari teknik *boosting*.

2. Metode

2.1 Data Set

Menggunakan dataset *e commerce womans e-commerce clothing reviews* dengan data publik dan format csv yang dapat diakses pada <https://www.kaggle.com/datasets/nicapotato/womens-e-commerce-clothing-reviews/> data yang berjumlah 28223 data.

2.2 Pembelajaran Ensemble

Pembelajaran ensemble adalah metode yang digunakan untuk menggabungkan dua atau lebih algoritma pembelajaran mesin untuk mendapatkan kinerja yang lebih baik daripada saat algoritma konstituen digunakan secara individu. Alih-alih bergantung pada satu model, prediksi peserta didik digabungkan dengan kombinasi untuk membuat perkiraan kecepatan yang lebih akurat. Paralel ansambel dan sekuensial adalah kategori umum dari metode ansambel. Metode paralel mengajarkan pengklasifikasi dasar yang berbeda secara mandiri dan menggunakan penggabung untuk menggabungkan prediksi. Algoritma *Random Forest* adalah kumpulan metode pengumpulan dan pengembangan paralel yang populer. Menggunakan gen pembelajar dasar, algoritma ansambel paralel meningkatkan keragaman dalam kelompok anggota [10]. Berbeda dengan teknik pembelajaran mesin konvensional yang bertujuan untuk mempelajari satu hipotesis dari data pelatihan, teknik pembelajaran ensemble membuat banyak hipotesis dan menggabungkannya untuk memecahkan masalah tertentu [11].

2.3 Random Forest

Random Forest adalah sebuah algoritma pembelajaran ensemble yang digunakan untuk klasifikasi, regresi, dan pemodelan. Ini adalah jenis pembelajaran kelompok yang menggabungkan prediksi dari model pembelajaran mesin yang lebih sederhana untuk membuat prediksi yang lebih akurat. Keunggulan besar menggunakan algoritma ini adalah kemampuan untuk mengatasi masalah overfitting yang sering terjadi pada model pohon keputusan. Ini dilakukan dengan memilih subset fitur secara acak. Kedua, *Random Forest* memiliki kemampuan untuk menangani data yang hilang. Selain itu, *Random Forest* biasanya memiliki kinerja yang sangat baik dalam situasi di mana data masukan terdiri dari banyak fitur, seperti data berdimensi tinggi. Namun, ada beberapa kendala saat menggunakan algoritma ini. Misalnya, lebih banyak pohon diperlukan untuk klasifikasi yang lebih akurat, tetapi terlalu banyak pohon akan memperlambat proses pelatihan model. Selain itu, *Random Forest* menjadi lebih lambat dalam membuat prediksi seiring dengan bertambahnya jumlah pohon Keputusan [12]. Algoritma *Random Forest* memiliki kemampuan untuk mengurangi jumlah variasi pohon keputusan, yang memungkinkannya digunakan pada dataset yang besar [13].

2.4 Teknik Boosting

Boosting adalah salah satu teknik machine learning yang dikenal sebagai teknik peningkatan dengan menggabungkan model lemah menjadi model yang lebih kuat untuk meningkatkan kinerja model prediktif yang kuat [14]. Pembelajaran serial yang natural merupakan keuntungan *boosting*, karena menghasilkan perkiraan dan generalisasi yang sangat baik. Dengan kata lain, pengklasifikasi yang lemah dipelajari secara berurutan. Tujuan dari penelitian ini adalah untuk mengurangi kesalahan model penggolong yang lebih awal. Sejauh ini, banyak strategi untuk meningkatkan telah diusulkan. Masing-masing meningkatkan kinerja kelas spesifikasi dengan mengubah beberapa langkah dari rencana peningkatan umum [15]. Ada beberapa algoritma dalam Teknik *boosting* seperti *Xgboost*, *Gradboost*, *LGBM* pastinya tiap algoritma memiliki kelebihan masing-masing.

2.5 Xgboost

Xgboost adalah model gabungan yang menggabungkan implementasi pohon keputusan yang efektif untuk menghasilkan model gabungan yang memiliki kinerja prediktif yang lebih baik daripada metode terpisah yang digunakan [16]. Kelebihan algoritma *Xgboost* adalah sebagai berikut: Pertama, algoritma *Xgboost* memiliki akurasi yang lebih tinggi daripada algoritma GBDT, yang hanya menggunakan ekspansi orde pertama. Kedua, dengan menambahkan jangka waktu reguler, modelnya lebih sederhana, yang secara efektif dapat mencegah model berlebihan. Yang ketiga, algoritma penginderaan renggang *Xgboost* mempelajari arah pemisahan pohon secara otomatis, sebagian kecil nilai yang hilang tidak dapat diproses selama tahap preprocessing. Kelemahan *Xgboost*, bagaimanapun, adalah perlunya melintasi kumpulan data selama proses pemisahan simpul pohon, yang memakan banyak waktu memori komputer [17].

2.6 Gradient Boosting

Pembelajaran mesin yang dikenal sebagai *Gradient Boost* menggunakan regresi produk dan klasifikasi berdasarkan model prediksi yang lemah, seperti keputusan pohon [18]. Gradien Boost dapat mendeteksi hubungan rumit dalam data *e-commerce* [19]. Metode peningkatan *Gradient* menggunakan pendekatan berurutan untuk menghasilkan prediksi. Setiap pohon keputusan dalam metode ini memprediksi kesalahan dari pohon keputusan sebelumnya [20]. Tiga komponen utama algoritma *Gradient Boost* adalah fungsi kerugian, pembelajar lemah, dan model aditif [21].

2.7 Light Gradient Boosting

Light Gradient boosting Machine (LGBM) adalah kerangka kerja peningkatan gradien yang terutama mengandalkan Algoritma Pohon Keputusan digunakan untuk tujuan klasifikasi dan pemeringkatan. Beroperasi berdasarkan prinsip pembelajaran ansambel, *LGBM* menggabungkan berbagai kelemahan pembelajar untuk membentuk pembelajar tunggal yang tangguh. Algoritme ini lebih disukai untuk menangani kumpulan data yang luas, mengingat kecepatannya kemampuan pemrosesan [11]. Khususnya, konsep yang digunakan dalam algoritma *LGBM* adalah GOSS (*Single-Sided Gradient Analysis*) dan GBDT (*Gradient boosting Decision Tree*). Banyak digunakan, algoritma pembelajaran yang terlibat dalam prediksi pembelajaran *LGBM* domain adalah yang tercepat di antara algoritma komputasi berbasis pohon karena berkembang secara vertikal [22].

2.8 Eksperimen

Pada Gambar 1 Tahap Eksperimen diatas diawali dengan mengunggah dataset *e-commerce* pada *google collaboratory*.



Gambar 1. Tahap Eksperimen

Kemudian dilanjutkan dengan pemrosesan data seperti konversi kata kecil, tokenisasi, lematisasi dilanjutkan dengan pelabelan data, kemudian pembagian data dan dilanjutkan dengan modeling data menggunakan algoritma *Random Forest* dikombinasi dengan Teknik *boosting* yang dilanjutkan dengan evaluasi dilengkapi beberapa analisis *accuracy*, *precision*, *recall*, dan *F1-Score*.

2.8.1 Pemrosesan, Pelabelan, dan Pembagian Data

Pemrosesan data awal, juga dikenal sebagai *preprocessing data*, adalah tahap awal dalam pemrosesan data untuk menghilangkan tanda baca, simbol, atau karakter selain abjad serta konversi kata kecil. Tahap ini termasuk menghilangkan tanda baca seperti titik, koma, tanda seru, tanda tanya, petik satu dan dua, sama dengan, dan simbol selain abjad. Selanjutnya akan dilakukan tokenisasi untuk memisahkan teks menjadi terpisah per kata dan dilanjutkan dengan lematisasi atau proses pemrosesan bahasa alami di mana kata-kata dalam teks diubah menjadi bentuk dasar atau kata dasar bertujuan untuk memotong kata-kata dalam teks menjadi bentuk dasar mereka, sehingga analisis teks dapat dilakukan dengan lebih efisien, misalnya dengan membagi kata-kata berdasarkan semantik atau sintaksis.

Pelabelan merupakan proses menambahkan atau menetapkan label atau kategori tertentu pada setiap contoh data dalam kumpulan data. Label-label ini menunjukkan apa yang diwakili oleh data. Bertujuan untuk membuat dataset yang dapat digunakan untuk pelatihan model pembelajaran mesin yang bersifat terawasi. Pelabelan untuk penelitian ini dibagi menjadi 2 yaitu Rekomendasi dan Tidak Rekomendasi.

Pembagian data, juga dikenal sebagai pembagian data, adalah proses membagi dataset menjadi subset yang saling eksklusif dan bertumpang tindih untuk tujuan tertentu, terutama dalam pengujian model dan pembelajaran mesin. Tujuan utama pembagian data adalah untuk mengisolasi sebagian dari dataset untuk digunakan dalam tahap pelatihan (*training*) model dan sebagian lainnya untuk digunakan dalam tahap evaluasi (*testing*) atau validasi model. Dataset biasanya terdiri dari setidaknya dua bagian: set pelatihan (*training set*) dan set pengujian (*testing set*).

2.8.2 Pemodelan Data

Pada tahap eksperimen ini menggunakan algoritma *Random Forest* dengan Teknik *Boosting* seperti *Xgboost*, *LGBM*, *Gradboost*. Selanjutnya ada beberapa pengaturan parameter untuk implementasi fungsi *Xgboost*, *LGBM*, dan *Gradboost* didasarkan pada parameter jumlah pohon atau *n_estimators*, *learning_rate*, dan *max_depth*. Parameter *n_estimators* menentukan jumlah pohon keputusan yang dibuat secara paralel, *learning_rate* adalah sebagai laju pembelajaran dan *max_depth* adalah penentu kedalaman maksimum.

Tabel 1 *Hyperparameter*

Model	<i>n_estimator</i>	<i>learning_rate</i>	<i>max_depth</i>
Boost	[100, 200]	[0.1, 0.2]	[5, 7, 9]
Random Forest	[100, 200]	-	-

Pada Tabel 1 *Hyperparameter* diatas ada beberapa *Hyperparameter* yang digunakan seperti, parameter

n_estimator, yang terdiri dari 100 dan 200 untuk menentukan batas jumlah pohon. Parameter *learning_rate*, yang terdiri dari 0,1 dan 0,2 bertujuan sebagai laju pembelajaran. Parameter *max_depth*, yang terdiri dari 5, 7, dan 9, dipilih untuk menentukan jumlah pemisahan dari setiap pohon keputusan. Untuk mendapatkan hasil terbaik berdasarkan parameter ini adalah teknik *Xgboost* yang digunakan. *Hyperparameter Random Forest* yaitu *n_estimator* yang terdiri dari 100 dan 200.

3. Hasil dan Pembahasan

Dari hasil uji yang ditampilkan pada Tabel 2, dilakukan pengujian model penggabungan algoritma yaitu RF-*Xgboost*, *RF-Gradient-Boosting*, *RF-LightGBM*. Implementasi ensemble menggunakan Teknik *majority voting* yaitu teknik yang menggunakan nilai mayoritas dari algoritma – algoritma individu dalam ensemble.

Tabel 2 Hasil Uji – Akurasi

Algoritma/ Model	Hyperparameter			Akurasi
	<i>n_estima tors</i>	<i>learning _rate</i>	<i>max_ depth</i>	
Random Forest + Xgboost (RF+Xgboost)	100	0.1	5	85.49%
			7	85.78%
			9	86.04%
		0.2	5	86.15%
			7	86.22%
			9	86.72%
	200	0.1	5	86.15%
			7	86.72%
			9	86.84%
		0.2	5	86.70%
			7	86.95%
			9	87.25%
Random Forest + LGBM (RF+LGBM)	100	0.1	5	86.29%
			7	86.00%
			9	86.33%
		0.2	5	86.11%
			7	86.70%
			9	86.37%
	200	0.1	5	86.17%
			7	86.37%
			9	86.55%
		0.2	5	86.88%
			7	86.79%
			9	86.86%
Random Forest + Gradient Boosting (RF+GB)	100	0.1	5	85.27%
			7	85.51%
			9	86.26%
		0.2	5	85.55%
			7	85.89%
			9	85.73%
	200	0.1	5	86.28%
			7	85.91%
			9	86.61%
		0.2	5	86.04%
			7	86.31%
			9	86.04%

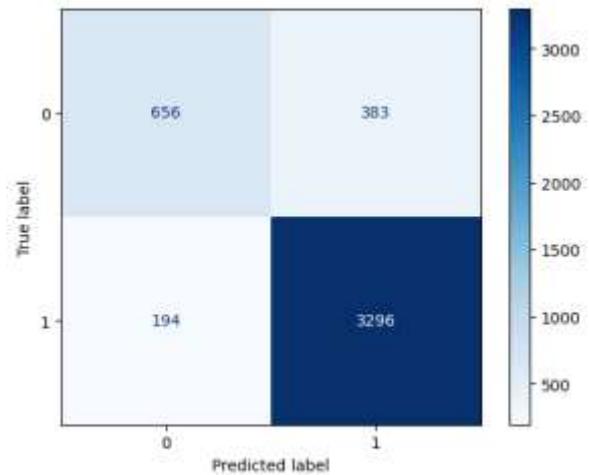
Tujuan dari penggabungan atau ensemble adalah menemukan performa terbaik dari algoritma (*boosting*) individu atau tunggal dalam merekomendasikan produk berbasis klasifikasi.

Pada uji coba model dilakukan pengaturan *hyperparameter* yaitu untuk menemukan parameter – parameter yang menghasilkan akurasi terbaik dari uji algoritma pada teknik *boosting*. Terdapat 2 pengaturan *Hyperparameter* yaitu pengaturan *Hyperparameter* pada *Random Forest* dan pengaturan *Hyperparameter* untuk algoritma dalam Teknik *boosting*. Tahap evaluasi menggunakan *confusion matrix* untuk mendapatkan perhitungan akurasi, presisi, *recall* dan *F1-score*. Berdasarkan penelitian dari [23] *confusion matrix* dapat digunakan untuk mengetahui akurasi, presisi, *recall* dan *F1-score* pada evaluasi klasifikasi sentiment analisis.

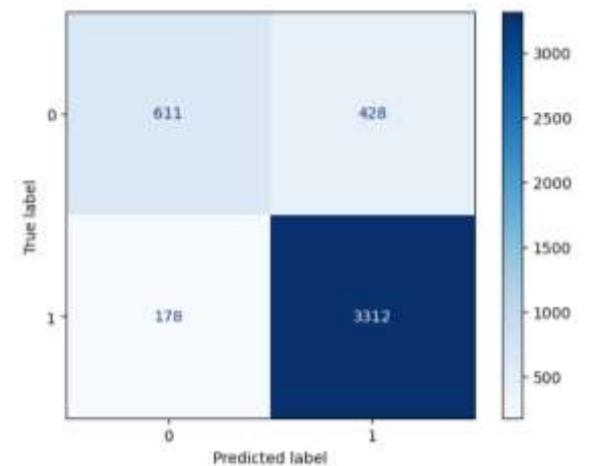
Pada Uji pertama, menggunakan penggabungan *Random Forest* dengan *Xgboost*. Hasil akurasi terbaik ditampilkan pada *n_estimator* 200, *learning rate* 0.2 dan *max_depth* 9 dengan hasil akurasi 87.25%. adanya pengaturan *Hyperparameter* terbukti memberikan peningkatan akurasi dalam model yang diusulkan. Pada uji kedua, menggunakan penggabungan *Random Forest* dengan *LightGBM*. Hasil akurasi terbaik ditampilkan pada *n_estimator* 200, *learning* 0.2 dan *max_depth* 5 dengan hasil akurasi 86.88%. berbeda dengan Teknik *Xgboost*, tingginya *max_depth* pada *LGBM* dapat menurunkan performa. Pada uji ketiga, menggunakan penggabungan *Random Forest* dengan *Gradient Boosting*. Hasil akurasi tertinggi ditampilkan pada *n_estimator* 200, *learning rate* 0.1 dan *max_depth* 9 dengan akurasi 86.61. Pada uji coba ketiga menunjukkan bahwa parameter *learning rate* juga menentukan Tingkat akurasi yang dihasilkan oleh Teknik *boosting*. Berbeda dengan dua algoritma lainnya, pada *RF-Gradient boosting* akurasi terbaik dihasilkan pada *learning_rate* 0.1 sedangkan algoritma seperti *RF-Xgboost* dan *RF-LGBM* adalah 0.2.

Dari tiga ujicoba dapat ditarik kesimpulan bahwa ensemble *Random Forest* dengan *Xgboost* lebih stabil dibandingkan penggabungan ensemble *Random Forest-Gradient boosting* dan *Random Forest-LGBM*. Teknik ensemble *Random Forest-Xgboost* menampilkan peningkatan akurasi dari tiap – tiap *Hyperparameter*. Selain itu, jika dibandingkan dengan penggabungan algoritma lainnya, *Random Forest-Xgboost* menghasilkan akurasi tertinggi. Hal ini membuktikan bahwa model yang diusulkan selain stabil dalam tiap pengaturan *Hyperparameter*, juga memberikan akurasi lebih baik dibandingkan Teknik *boosting* lainnya.

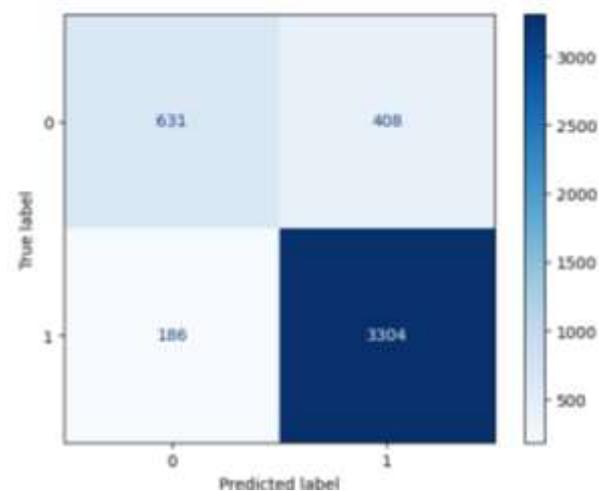
Hasil uji pemodelan ditampilkan dalam *Confusion matrix* untuk mengetahui nilai prediksi aktual dari model yang diusulkan. Gambar 2 *Confusion Matrix*: (i) *RF-Xgboost* (ii) *RF-Gradient boosting* (iii) *RF-LightGBM*, bagian (i) menunjukkan *Confusion matrix* dengan akurasi tertinggi dari *RF-Xgboost* sebesar 87.25%, bagian (ii) menunjukkan *Confusion matrix* dengan akurasi tertinggi RF-GB sebesar 86,61% dan bagian (iii) menunjukkan *Confusion matrix* dengan akurasi tertinggi *RF-LightGBM* sebesar 86,88%. Dari tiga bagian *Confusion matrix* tersebut terdapat kesamaan bahwa nilai *true positif (TP)* memiliki nilai terbesar dibandingkan nilai yang lain.



(i)



(ii)



(iii)

Gambar 2. *Confusion Matrix*: (i) *RF-Xgboost* (ii) *RF-Gradient boosting* (iii) *RF-LightGBM*

Evaluasi kedua adalah analisis presisi. Pada Tabel 3 matriks evaluasi, presisi (*precision*) terbaik adalah ensemble *RF-Xgboost* yaitu 0.90 atau 90% sedangkan Teknik penggabungan ensemble lainnya pada 0.89 atau 89%.

Dalam hal ini *RF-Xgboost* mampu memprediksi secara akurat kelas positif. Kelas yang diprediksi positif benar – benar memang benar positif. Evaluasi ketiga adalah analisis *recall*. Pada tabel 3 menunjukkan bahwa ensemble *RF-LGBM* dan *RF-GB* memberikan *recall* terbaik dibandingkan *RF-Xgboost* yaitu dengan nilai 0.95 atau 95%. Model yang diusulkan menghasilkan 95% kelas positif berhasil diidentifikasi. Artinya, 95% kelas positif diprediksi benar oleh model yang diusulkan. Dalam hal ini, *RF-Xgboost* tidak lebih baik dari *RF-LGBM* dan *RF-GB* dalam hal *recall*.

Evaluasi terakhir adalah analisis *F1-Score*. Pada tabel 3, menunjukkan nilai yang sama antara *RF-Xgboost*, *RF-GB* dan *RF-LGBM* yaitu 0.92 atau 92%. Analisis *F1-Score* merupakan analisis gabungan dari presisi dan *recall* digunakan untuk menunjukkan keseimbangan antara presisi dan *recall*. Dari hasil yang diperoleh, maka dapat disimpulkan bahwa kinerja model Ensemble *Random Forest* dengan Teknik *boosting* menunjukkan kinerja yang baik. Selain itu, tingginya nilai *F1-Score* yang dihasilkan mampu mengurangi nilai kelas *false*.

4. Kesimpulan

Pembelajaran ensemble *Random Forest* dan Teknik *Boosting* yang digunakan mampu menangani permasalahan rekomendasi produk berbasis klasifikasi ulasan. Dari penggabungan *algoritma random forest* dan Teknik *boosting* seperti *XGBoost*, *Gradient Boosting* dan *LightGBM* serta adanya pengaturan *hyperparameter* seperti *n_estimator*, *learning rate* dan *max depth* dapat menemukan Tingkat akurasi pada masing – masing penggabungan (ensemble). Dari hasil uji pemodelan dan analisis matriks evaluasi dapat disimpulkan bahwa rekomendasi produk berbasis klasifikasi dengan ensemble *Random Forest* dan Teknik *boosting* memberikan hasil akurasi yang baik. Dari ketiga model yang diusulkan, ensemble *Random Forest* dengan *Xgboost* memberikan nilai akurasi tertinggi atau terbaik dibandingkan ensemble *Random Forest-GB* dan ensemble *Random Forest-LightGBM*. Berdasarkan hasil uji, ensemble *Random Forest-Xgboost* menghasilkan akurasi 87.25%, lebih tinggi dibandingkan *Random Forest-GB* 86.61 dan *Random-Forest LGBM* 86.88%.

Pada analisis matriks evaluasi menunjukkan *Random Forest-Xgboost* menghasilkan presisi dan *recall* lebih tinggi dibandingkan ensemble lainnya. Berdasarkan hasil uji ini dapat disimpulkan Ensemble *Random Forest-Xgboost* mampu menghasilkan akurasi terbaik dalam rekomendasi produk *e-commerce* berbasis klasifikasi. Pada penelitian selanjutnya dilakukan uji model pembelajaran ensemble dengan beberapa algoritma seperti *KNN*, *SVM* dan *Linier Regression* serta implementasi Teknik ensemble lainnya seperti *bagging* dan *stacking* untuk menemukan akurasi yang lebih baik dari model yang diusulkan. Serta penggunaan Teknik *up sampling* atau *down sampling* untuk penyeimbangan data sehingga dapat memperbaiki matriks evaluasi presisi, *recall* dan *F1-Score*.

Daftar Pustaka

- [1] D. M. Alghazzawi, A. G. A. Alquraishiee, S. K. Badri, and S. H. Hasan, "ERF-XGB: Ensemble Random Forest-Based XG Boost for Accurate Prediction and Classification of E-Commerce Product Review," *Sustainability (Switzerland)*, vol. 15, no. 9, May 2023, doi: 10.3390/su15097076.
- [2] Stephenie, B. Warsito, and A. Prahutama, "Sentiment Analysis on Tokopedia Product Online Reviews Using Random Forest Method," in *E3S Web of Conferences*, EDP Sciences, Nov. 2020. doi: 10.1051/e3sconf/202020216006.
- [3] N. Verma, S. Sood, K. Kumari, and N. Kumari, "The Impact of Product Reviews on E-Commerce Performance: A Comprehensive Review," *Int J Res Appl Sci Eng Technol*, vol. 11, no. 7, pp. 1258–1264, Jul. 2023, doi: 10.22214/ijraset.2023.54849.
- [4] A. H. Hasugian, M. Fakhriza, and D. Zukhoiriyah, "Analisis Sentimen Pada Review Pengguna E-Commerce Menggunakan Algoritma Naïve Bayes," *J-SISKO TECH (Jurnal Teknologi Sistem Informasi dan Sistem Komputer TGD)*, vol. 6, no. 1, p. 98, Jan. 2023, doi: 10.53513/jsk.v6i1.7400.
- [5] J. Mutinda, W. Mwangi, and G. Okeyo, "Sentiment Analysis of Text Reviews Using Lexicon-Enhanced Bert Embedding (LeBERT) Model with Convolutional Neural Network," *Applied Sciences (Switzerland)*, vol. 13, no. 3, Feb. 2023, doi: 10.3390/app13031445.
- [6] A. Onan, "Sentiment analysis on product reviews based on weighted word embeddings and deep neural networks," in *Concurrency and Computation: Practice and Experience*, John Wiley and Sons Ltd, Dec. 2021. doi: 10.1002/cpe.5909.
- [7] A. A. Farisi, Y. Sibaroni, and S. Al Faraby, "Sentiment analysis on hotel reviews using Multinomial Naïve Bayes classifier," in *Journal of Physics: Conference Series*, Institute of Physics Publishing, May 2019. doi: 10.1088/1742-6596/1192/1/012024.
- [8] Q.-F. Li and Z.-M. Song, "High-performance concrete strength prediction based on ensemble learning," *Constr Build Mater*, vol. 324, p. 126694, Mar. 2022, doi: 10.1016/j.conbuildmat.2022.126694.
- [9] Z. Shahbazi, D. Hazra, S. Park, and Y. C. Byun, "Toward Improving the Prediction Accuracy of Product Recommendation System Using Extreme Gradient Boosting and Encoding Approaches," *Symmetry (Basel)*, vol. 12, no. 9, p. 1566, Sep. 2020. doi: 10.3390/sym12091566.
- [10] I. D. Mienye and Y. Sun, "A Survey of Ensemble Learning: Concepts, Algorithms, Applications, and Prospects," *IEEE Access*, vol. 10. Institute of Electrical and Electronics Engineers Inc., pp. 99129–99149, 2022. doi: 10.1109/ACCESS.2022.3207287.
- [11] Z. Li and N. Zhang, "Short-Term Demand Forecast of E-Commerce Platform Based on ConvLSTM Network," *Comput Intell Neurosci*, vol. 2022, 2022, doi: 10.1155/2022/5227829.
- [12] P. D. Caie, N. Dimitriou, and O. Arandjelović, "Precision medicine in digital pathology via image analysis and machine learning," in *Artificial Intelligence and Deep Learning in Pathology*, Elsevier, 2021, pp. 149–173. doi: 10.1016/B978-0-323-67538-3.00008-7.
- [13] S. Hong and H. S. Lynn, "Accuracy of random-forest-based imputation of missing data in the presence of non-normality, non-linearity, and interaction," *BMC Med Res Methodol*, vol. 20, no. 1, p. 199, Dec. 2020, doi: 10.1186/s12874-020-01080-1.
- [14] M. Alojail and S. Bhatia, "A Novel Technique for Behavioral Analytics Using Ensemble Learning Algorithms in E-Commerce," *IEEE Access*, vol. 8, pp. 150072–150080, 2020, doi: 10.1109/ACCESS.2020.3016419.
- [15] J. Tanha, Y. Abdi, N. Samadi, N. Razzaghi, and M. Asadpour, "Boosting methods for multi-class imbalanced data classification: an experimental review," *J Big Data*, vol. 7, no. 1, Dec. 2020, doi: 10.1186/s40537-020-00349-y.

- [16] S. Ben Jabeur, S. Mefteh-Wali, and J. L. Viviani, "Forecasting gold price with the XGBoost algorithm and SHAP interaction values," *Ann Oper Res*, Mar. 2021, doi: 10.1007/s10479-021-04187-w.
- [17] "Retracted: Analysis of E-Commerce Marketing Strategy Based on Xgboost Algorithm," *Advances in Multimedia*, vol. 2023, pp. 1–1, Dec. 2023, doi: 10.1155/2023/9805382.
- [18] K. Singh, P. M. Booma, and U. Eaganathan, "E-Commerce System for Sale Prediction Using Machine Learning Technique," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Dec. 2020. doi: 10.1088/1742-6596/1712/1/012042.
- [19] A. Y. A Bani Ahmad, T. Naidu Gongada, G. Shrivastava, R. Singh Gabbi, S. Islam, and K. Nagaraju, "International Journal of INTELLIGENT SYSTEMS AND APPLICATIONS IN ENGINEERING E-Commerce Trend Analysis and Management for Industry 5.0 using User Data Analysis." [Online]. Available: www.ijisae.org
- [20] J. Kubrusly, A. L. Neves, and T. L. Marques, "A Statistical Analysis of Textual E-Commerce Reviews Using Tree-Based Methods," *Open J Stat*, vol. 12, no. 03, pp. 357–372, 2022, doi: 10.4236/ojs.2022.123023.
- [21] R. Jhangiani, D. Bein, and A. Verma, "Machine Learning Pipeline for Fraud Detection and Prevention in E-Commerce Transactions," 2019.
- [22] R. M. Aziz, M. F. Baluch, S. Patel, and A. H. Ganie, "LGBM: a machine learning approach for Ethereum fraud detection," *International Journal of Information Technology (Singapore)*, vol. 14, no. 7, pp. 3321–3331, Dec. 2022, doi: 10.1007/s41870-022-00864-6.
- [23] M. J. Hossain, D. Das Joy, S. Das, and R. Mustafa, "Sentiment Analysis on Reviews of E-commerce Sites Using Machine Learning Algorithms," in *2022 International Conference on Innovations in Science, Engineering and Technology, ICISSET 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 522–527. doi: 10.1109/ICISSET54810.2022.9775846.