

Evaluasi Perbandingan Model *XGBoost*, *Random Forest*, *LightGBM*, dan *Artificial Neural Network* dalam Klasifikasi Kerawanan Pangan

Mardatunnisa Isnaini dkk.



Volume 14, Issue 1, Pages 30–48, April 2026

Diterima 17 Desember 2025, Direvisi 19 Februari 2026, Disetujui 24 Februari 2026, Diterbitkan 6 April 2026

To Cite this Article : M. Isnaini dkk., "Evaluasi Perbandingan Model *XGBoost*, *Random Forest*, *LightGBM*, dan *Artificial Neural Network* dalam Klasifikasi Kerawanan Pangan", *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 14, no. 1, pp. 30–48, 2026, <https://doi.org/10.37905/euler.v14i1.36227>

© 2026 by author(s)

JOURNAL INFO • EULER : JURNAL ILMIAH MATEMATIKA, SAINS DAN TEKNOLOGI



Homepage	:	http://ejournal.ung.ac.id/index.php/euler/index
Journal Abbreviation	:	Euler J. Ilm. Mat. Sains dan Teknol.
Frequency	:	Three times a year
Publication Language	:	English (preferable), Indonesia
DOI	:	https://doi.org/10.37905/euler
Online ISSN	:	2776-3706
License	:	Creative Commons Attribution-NonCommercial 4.0 International License
Publisher	:	Department of Mathematics, Universitas Negeri Gorontalo
Country	:	Indonesia
OAI Address	:	http://ejournal.ung.ac.id/index.php/euler/oai
Google Scholar ID	:	QF_r-gAAAAJ
Email	:	euler@ung.ac.id

JAMBURA JOURNAL • FIND OUR OTHER JOURNALS



Jambura Journal of Biomathematics



Jambura Journal of Mathematics



Jambura Journal of Mathematics Education



Jambura Journal of Probability and Statistics



Evaluasi Perbandingan Model XGBoost, Random Forest, LightGBM, dan Artificial Neural Network dalam Klasifikasi Kerawanan Pangan

Mardatunnisa Isnaini¹, Dela Gustiara¹, Rizqi Annafi Muhadi^{1,*}, Shalsabila Shafa¹, Bagus Sartono¹, Aulia Rizki Firdawanti¹, Budi Susetyo¹, Gerry Alfa Dito¹

¹Program Studi Statistika dan Sains Data, IPB University, Bogor, 16680, Indonesia

ARTICLE HISTORY

Diterima 17 Desember 2025
Direvisi 19 Februari 2026
Disetujui 24 Februari 2026
Diterbitkan 6 April 2026

KATA KUNCI

Kerawanan Pangan
Machine Learning
SMOTE

KEYWORDS

Food Insecurity
Machine Learning
SMOTE

ABSTRAK. Kerawanan pangan masih menjadi persoalan serius di tingkat rumah tangga, khususnya di wilayah berpenduduk padat seperti Jawa Barat, sehingga diperlukan pendekatan analisis yang mampu memetakan kelompok berisiko secara akurat. Penggunaan algoritma machine learning berpotensi meningkatkan akurasi dan ketepatan klasifikasi kerawanan pangan berbasis data survei. Penelitian ini bertujuan membandingkan performa serta kemampuan identifikasi variabel penting dari empat algoritma machine learning, yaitu Random Forest, Light Gradient Boosting Machine (LightGBM), Extreme Gradient Boosting (XGBoost), dan Artificial Neural Network (ANN) dalam memprediksi tingkat kerawanan pangan rumah tangga. Penelitian menggunakan data SUSENAS 2023 yang mencakup 26.012 rumah tangga dengan 14 variabel prediktor, serta klasifikasi kerawanan pangan berdasarkan Food Insecurity Experience Scale (FIES). Ketidakeimbangan kelas ditangani menggunakan Synthetic Minority Over-sampling Technique (SMOTE) dengan skema 10-fold cross-validation. Hasil penelitian menunjukkan bahwa XGBoost menghasilkan akurasi tertinggi sebesar 71%, sedangkan Random Forest memberikan balanced accuracy terbaik pada skenario SMOTE. Selain itu, keempat algoritma secara konsisten menempatkan indeks kekayaan sebagai prediktor terpenting berdasarkan hasil variable importance, diikuti oleh variabel terkait akses air dan bantuan pangan. Dengan demikian, XGBoost direkomendasikan dari sisi akurasi, sementara Random Forest unggul dalam balanced accuracy dan stabilitas prediksi.

ABSTRACT. Food insecurity remains a serious household-level issue, particularly in densely populated regions such as West Java, highlighting the need for analytical approaches capable of accurately identifying vulnerable groups. Machine learning algorithms offer the potential to improve the accuracy and precision of food insecurity classification based on survey data. This study aims to compare the predictive performance and variable importance identification of four machine learning algorithms—Random Forest, Light Gradient Boosting Machine (LightGBM), Extreme Gradient Boosting (XGBoost), and Artificial Neural Network (ANN)—in predicting household food insecurity status. The analysis employs SUSENAS 2023 data covering 26,012 households with 14 predictor variables, and food insecurity is classified using the Food Insecurity Experience Scale (FIES). Class imbalance is addressed using the Synthetic Minority Over-sampling Technique (SMOTE) within a 10-fold cross-validation framework. The results show that XGBoost achieves the highest accuracy of 71%, while Random Forest provides the best balanced accuracy under the SMOTE scenario. Moreover, all algorithms consistently identify the Wealth Index as the most influential predictor based on their respective Variable Importance measures, followed by variables related to water access and food assistance. Accordingly, XGBoost is recommended in terms of accuracy, whereas Random Forest demonstrates superior balanced accuracy and prediction stability.



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International License. **Editorial of EULER:** Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

1. Pendahuluan

Pangan merupakan kebutuhan dasar manusia dan elemen fundamental dalam ketahanan pangan nasional. Undang-Undang Republik Indonesia Nomor 18 Tahun 2012 tentang Pangan menegaskan bahwa ketahanan pangan mencerminkan terpenuhinya pangan yang cukup, am-

*Penulis Korespondensi.

an, bergizi, beragam, dan terjangkau bagi seluruh masyarakat untuk mendukung kehidupan yang sehat, aktif, dan produktif secara berkelanjutan [1]. Meskipun dijamin secara hukum, pencapaian ketahanan pangan, khususnya di tingkat rumah tangga, masih menghadapi tantangan yang kompleks dan multidimensi.

Secara global, kerawanan pangan menunjukkan tren peningkatan yang mengkhawatirkan, dengan prevalensi kerawanan pangan moderat hingga parah meningkat dari 22,6% pada tahun 2014 menjadi 26,5% pada tahun 2019 [2], serta jumlah penduduk kurang gizi yang tetap tinggi mencapai 821 juta jiwa pada tahun 2018 [3]. Walaupun angka ini berasal dari 2018, tren meningkatnya kerawanan pangan tetap relevan untuk analisis terkini. Tren ini menjadi relevan bagi wilayah berpenduduk padat seperti Provinsi Jawa Barat yang memiliki tekanan sosial-ekonomi dan ketimpangan akses pangan yang serupa. Data BPS tahun 2023 menunjukkan bahwa sekitar 3,67 juta penduduk Jawa Barat hidup di bawah garis kemiskinan, dengan 74,72% pengeluaran rumah tangga miskin dialokasikan untuk pangan, yang mencerminkan tingginya kerentanan terhadap fluktuasi harga dan guncangan ekonomi [4].

Sejumlah penelitian terdahulu telah memanfaatkan data survei rumah tangga untuk memetakan dan mengklasifikasikan status kerawanan pangan di Indonesia, termasuk Jawa Barat, menggunakan pendekatan statistik dan algoritma klasifikasi. Beberapa studi menggunakan metode *ensemble* untuk mengklasifikasikan skala pengalaman kerawanan pangan (*FIES*) dan mengidentifikasi faktor penentunya [5, 6]. Studi terbaru menunjukkan bahwa *Random Forest* dengan penanganan ketidakseimbangan data mampu memberikan kinerja yang relatif baik [6]. Pendekatan *machine learning* dipilih karena mampu menangkap hubungan nonlinier dan interaksi kompleks antara faktor sosial, ekonomi, dan lingkungan yang sulit dimodelkan menggunakan regresi tradisional.

Secara global, penerapan algoritma *machine learning* seperti *Random Forest*, *Artificial Neural Network* (ANN), dan metode *boosting* juga telah banyak digunakan dalam analisis kerawanan pangan dan malnutrisi anak. Salah satu penelitian menunjukkan bahwa pendekatan *machine learning* efektif dalam memprediksi dampak *food insecurity* terhadap konsumsi nutrisi dan status gizi anak [7]. Selain itu, studi komparatif lain membandingkan performa *Random Forest*, *XGBoost*, dan *LightGBM* dalam konteks klasifikasi indikator pembangunan dan menunjukkan bahwa algoritma *boosting* modern memiliki keunggulan dalam akurasi dan efisiensi komputasi [8]. Tinjauan sistematis menegaskan bahwa *Random Forest* dan ANN mendominasi penelitian prediksi masalah sosial di Indonesia, namun eksplorasi algoritma *boosting* modern serta evaluasi komprehensif antar model dalam satu kerangka yang konsisten masih relatif terbatas [9].

Namun, penelitian tersebut masih terbatas pada jumlah variabel dan belum membandingkan algoritma *boosting* modern seperti *XGBoost* dan *LightGBM* pada dataset SUSENAS skala besar dan terbaru. Dengan demikian, masih terdapat celah penelitian terkait evaluasi komprehensif performa berbagai algoritma *machine learning* dalam konteks kerawanan pangan rumah tangga pada data SUSENAS skala besar tahun terbaru. Analisis literatur yang berfokus pada Indonesia dan khususnya Jawa Barat menunjukkan adanya upaya pemetaan dan klasifikasi status kerawanan pangan berbasis survei rumah tangga untuk mengidentifikasi karakteristik rumah tangga rentan dan model klasifikasi yang memadai [10].

Berdasarkan latar belakang yang telah dijelaskan pada paragraf sebelumnya, kontribusi utama penelitian ini adalah membandingkan empat algoritma *machine learning* menggunakan skenario penyeimbangan data untuk memprediksi kerawanan pangan rumah tangga secara lebih akurat. Tujuan utama penelitian ini adalah membandingkan kinerja prediktif keempat algoritma *machine learning* tersebut dalam mengklasifikasikan tingkat kerawanan pangan di

Provinsi Jawa Barat, serta menganalisis pengaruh faktor ekonomi, sosial, dan lingkungan terhadap tingkat kerawanan pangan melalui identifikasi variabel-variabel yang paling berkontribusi dalam model terbaik. Dengan demikian, penelitian ini diharapkan dapat menghasilkan model prediktif yang lebih akurat dan informatif, yang tidak hanya unggul dari sisi performa statistik, tetapi juga mampu memberikan dasar empiris yang kuat bagi perumusan kebijakan penanggulangan kerawanan pangan yang lebih tepat sasaran di Jawa Barat.

2. Metode

2.1. Data dan Variabel Penelitian

Penelitian ini menggunakan data SUSENAS 2023 yang diterbitkan oleh Badan Pusat Statistik (BPS) sebagai data sekunder, mencakup 26.012 rumah tangga di Provinsi Jawa Barat. Variabel penelitian terdiri atas variabel dependen dan independen. Variabel dependen berupa status kerawanan pangan rumah tangga yang diklasifikasikan secara biner berdasarkan *Food Insecurity Experience Scale* (FIES). Skor FIES dihitung dari delapan pertanyaan SUSENAS yang dikodekan secara dikotomis (1 = mengalami, 0 = tidak mengalami), sehingga menghasilkan skor total 0–8. Selanjutnya, skor tersebut diklasifikasikan menjadi aman pangan ($Y = 1$) untuk skor 0–2 dan rawan pangan ($Y = 0$) untuk skor 3–8, mengacu pada pedoman *Food and Agriculture Organization of the United Nations* (FAO) dan BPS. Daftar lengkap variabel penelitian yang digunakan disajikan pada **Tabel 1**.

Tabel 1. Variabel penelitian

Variabel	Keterangan	Skala
Y	Kerawanan Pangan	Biner
X1	Tipe Wilayah (Perkotaan/Perdesaan)	Nominal
X2	Sumber Air Minum	Rasio
X3	Lokasi Sumber Air	Ordinal
X4	Kekurangan Air 24 Jam	Ordinal
X5	Kualitas Fisik Air (Fisik)	Ordinal
X6	Indeks Kekayaan	Ordinal
X7	Penerima KKS	Ordinal
X8	PKH: Belanja Pangan	Nominal
X9	Penerima BPNT	Ordinal
X10	Penggunaan BPNT Okt 2023	Nominal
X11	Penggunaan BPNT Nov 2023	Nominal
X12	Penggunaan BPNT Des 2023	Nominal
X13	Penggunaan BPNT Jan 2024	Nominal
X14	Penerima Bantuan Beras	Ordinal

2.2. Prosedur Penelitian

Penelitian ini memanfaatkan empat algoritma klasifikasi dalam *Machine Learning* yaitu *Random Forest*, *Light Gradient Boosting Machine* (LightGBM), *Extreme Gradient Boosting* (XGBoost), dan *Artificial Neural Network* (ANN). Prosedur analisis data yang dilakukan meliputi tahapan-tahapan berikut:

1. Menginput data kerawanan pangan (termasuk faktor ekonomi, sosial, dan lingkungan) dengan total 26.012 data dan 14 variabel prediktor.
2. Tahap *preprocessing* meliputi *data cleaning* dan transformasi data. *Missing values* diimputasi menggunakan median untuk variabel numerik dan modus untuk variabel kategorikal, sedangkan *outliers* diidentifikasi dengan metode *Interquartile Range* (IQR) dan ditangani melalui *winsorizing*. Konversi variabel kategorikal dilakukan menggunakan *one-hot enco-*

- ding, sementara normalisasi atau standarisasi fitur numerik hanya diterapkan pada model ANN, sedangkan model berbasis pohon menggunakan data tanpa transformasi skala.
3. Menangani ketidakseimbangan kelas menggunakan *Synthetic Minority Over-sampling Technique* (SMOTE), yang diterapkan hanya pada data pelatihan (*training set*) di setiap *fold cross-validation*, sehingga tidak terjadi *data leakage* pada data pengujian.
 4. Melakukan analisis algoritma *Random Forest* menggunakan skema *Cross-Validation*:
 - Validasi model dilakukan menggunakan *stratified k-fold cross-validation* (10-fold) untuk menjaga proporsi kelas pada setiap *fold*.
 - Pada setiap *fold*, data dibagi menjadi data pelatihan dan data pengujian, kemudian SMOTE diterapkan pada data pelatihan.
 - Membangun model *Random Forest* pada setiap iterasi menggunakan data pelatihan hasil SMOTE.
 - Menyesuaikan parameter utama, seperti jumlah pohon (*n_{tree}*) dengan rentang 500–700 dan jumlah variabel pada setiap percabangan (*m_{try}*) dengan rentang 1–30, *maxdepth* dengan rentang 2–20, dan *minimum_n* dengan rentang 2–20 untuk meningkatkan performa dan menghindari *overfitting*.
 - Mengevaluasi performa model menggunakan metrik akurasi dan *balanced accuracy*, serta mengidentifikasi variabel berpengaruh melalui *variable importance*.
 5. Melakukan analisis algoritma *LightGBM* menggunakan skema *Cross-Validation*:
 - Validasi model dilakukan menggunakan *stratified k-fold cross-validation* (10-fold) untuk menjaga proporsi kelas pada setiap *fold*.
 - Pada setiap *fold*, SMOTE diterapkan pada data pelatihan, sedangkan data pengujian tidak dilakukan *oversampling*.
 - Membangun model *LightGBM* dengan teknik *Histogram-based splitting* dan *Leaf-wise tree growth*.
 - Melakukan *tuning* parameter utama dengan membangun 200 pohon (*n_{rounds}*) menggunakan laju pembelajaran 0,1, membatasi kompleksitas pohon dengan maksimum 31 daun (*num_leaves*), dan menerapkan *subsampling* fitur 0,9 dan *subsampling* data 0,8 untuk meningkatkan generalisasi model.
 - Mengevaluasi model menggunakan metrik akurasi dan *balanced accuracy*, serta menganalisis *variable importance*.
 6. Melakukan analisis algoritma *XGBoost* menggunakan skema *Cross-Validation*:
 - Validasi model dilakukan menggunakan *stratified k-fold cross-validation* (10-fold) untuk menjaga proporsi kelas pada setiap *fold*.
 - Menerapkan SMOTE pada data pelatihan di setiap *fold* sebelum proses pelatihan model.
 - Melakukan proses *boosting* menggunakan algoritma *XGBoost* untuk meminimalkan *error* secara bertahap.
 - Melakukan *tuning* parameter dengan *learning_rate* 0,0005–0,1, *loss_reduction* menggunakan rentang *default* dari *library dials*, *sample_size* menggunakan rentang *default* dari fungsi *sample_prop()*, *mtry* dengan rentang 1–80, dan *stop_iter* sebanyak 10–50 iterasi.
 - Mengevaluasi performa model menggunakan akurasi dan *balanced accuracy*, serta mengidentifikasi variabel berpengaruh berdasarkan *gain*, *cover*, dan *frequency*.
 7. Melakukan analisis algoritma ANN menggunakan skema *Cross-Validation*:
 - Validasi model dilakukan menggunakan *stratified k-fold cross-validation* (10-fold) untuk menjaga proporsi kelas pada setiap *fold*.

- Pada setiap *fold*, SMOTE diterapkan pada data pelatihan sebelum proses pelatihan ANN.
 - Arsitektur ANN terdiri dari 14 neuron pada *input layer*, satu *hidden layer* dengan 4–16 neuron beraktivasi *sigmoid*, dan satu *output layer* berfungsi logistik, dilatih menggunakan *backpropagation* dengan *batch size* 8, 50–150 *epoch*.
 - Melatih model ANN pada setiap *fold* hingga mencapai konvergensi dan mengevaluasi performa menggunakan akurasi dan *balanced accuracy*.
8. Mengevaluasi performa klasifikasi setiap model dengan mempertimbangkan *balanced accuracy*, akurasi, sensitivitas, dan spesifisitas untuk menentukan model dengan kinerja paling optimal pada data tidak seimbang.

2.3. Random Forest

Random Forest merupakan metode klasifikasi *ensemble* yang membangun banyak pohon keputusan secara acak dan menggabungkan hasil prediksi melalui mekanisme *majority voting*. Pada penelitian ini, parameter utama yang digunakan meliputi jumlah pohon (*ntree*) dan jumlah variabel yang dipilih pada setiap percabangan (*mtry*). Penalaan parameter dilakukan menggunakan *stratified 10-fold cross-validation* dengan penerapan SMOTE pada data pelatihan di setiap *fold* untuk menangani ketidakseimbangan kelas. Kinerja model dievaluasi menggunakan akurasi, *balanced accuracy*, sensitivitas, spesifisitas, dan *PR-AUC*, serta dianalisis lebih lanjut melalui *variable importance* untuk mengidentifikasi variabel yang paling berpengaruh dalam klasifikasi kerawanan pangan. *Decision tree* sendiri merupakan metode yang membagi data secara bertahap berdasarkan aturan pemisahan terbaik dengan mengacu pada nilai entropi sebagai ukuran ketidakpastian, sebagaimana dirumuskan pada pers. (1). Proses pemisahan tersebut bertujuan untuk memaksimalkan nilai *information gain* yang dinyatakan pada pers. (2).

$$E(D) = -p_1 \log p_1 - p_2 \log p_2, \quad (1)$$

$$IG = E(D) - \left(\frac{|D_1|}{|D|} E(D_1) + \frac{|D_2|}{|D|} E(D_2) \right) \quad (2)$$

Salah satu kelebihan utama metode *Random Forest* terletak pada kemampuannya dalam mengidentifikasi *variable importance*, yaitu ukuran kontribusi setiap variabel terhadap kinerja prediksi model. Nilai *variable importance* diperoleh berdasarkan besarnya penurunan nilai entropi yang dihasilkan oleh suatu fitur pada seluruh pohon yang terbentuk dalam model. Variabel yang memiliki nilai *importance* tinggi menunjukkan bahwa variabel tersebut berperan penting dalam menentukan hasil prediksi, sehingga dapat dimanfaatkan untuk mengungkap faktor-faktor utama yang berpengaruh dalam proses klasifikasi [11, 12].

2.4. Light Gradient Boosting Machine (LightGBM)

Light Gradient Boosting Machine (LightGBM) merupakan algoritma *gradient boosting* berbasis pohon keputusan yang dikembangkan untuk memproses data berukuran besar secara cepat. Efisiensi ini dicapai melalui mekanisme *histogram-based decision tree learning*, yaitu teknik pengelompokan nilai fitur ke dalam *bin* sehingga proses pembelajaran menjadi lebih cepat dan stabil [10]. Selain itu, LightGBM menggunakan strategi pertumbuhan pohon secara *leaf-wise*, yang memungkinkan model menangkap interaksi fitur yang lebih kompleks dibandingkan metode *level-wise* pada algoritma *boosting* tradisional [12, 13]. Algoritma ini juga menyediakan parameter penting seperti *learning rate*, *num_leaves*, *max_depth*, *feature fraction*, dan *bagging fraction* yang dapat disesuaikan untuk meningkatkan akurasi sekaligus mengontrol risiko *overfitting*. Kinerja LightGBM dievaluasi menggunakan akurasi, *balanced accuracy*, sensitivitas,

spesifisitas, dan *PR-AUC* berdasarkan hasil prediksi pada data pengujian di setiap *fold*. Berbagai studi menunjukkan bahwa LightGBM mampu bekerja sangat baik pada data *tabular*, deret waktu, maupun data visual, termasuk dalam klasifikasi citra yang memanfaatkan fitur warna berbasis HSV, karena kemampuannya mengenali perbedaan pola secara efisien dalam ruang fitur berdimensi tinggi [14, 15].

Log-loss berperan sebagai pengukur kesalahan prediksi pada model klasifikasi biner, di mana nilai *log-loss* yang semakin kecil menunjukkan bahwa hasil prediksi model semakin mendekati kebenaran. Perhitungan *log-loss* mengikuti formulasi matematis yang ditampilkan pada pers. (3).

$$L(y, \hat{y}) = - \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]. \quad (3)$$

Dalam masalah klasifikasi biner, digunakan fungsi *sigmoid* untuk mengubah keluaran model yang masih berupa nilai *logit* menjadi probabilitas dengan rentang antara 0 hingga 1. Dengan cara ini, hasil prediksi dapat dengan mudah diinterpretasikan sebagai peluang suatu data termasuk ke kelas tertentu. Bentuk matematis dari fungsi *sigmoid* tersebut ditampilkan pada pers. (4).

$$\hat{y} = \frac{1}{1 + e^{-F(x)}}. \quad (4)$$

Probabilitas yang dihasilkan oleh model tersebut kemudian digunakan untuk menentukan kelas prediksi. Apabila nilai \hat{y} berada di atas 0,5, maka data diklasifikasikan sebagai kelas 1. Sebaliknya, jika nilai \hat{y} berada di bawah 0,5, model akan menetapkan data tersebut sebagai kelas 0.

2.5. Extreme Gradient Boosting (XGBoost)

Extreme Gradient Boosting (XGBoost) merupakan algoritma yang dikembangkan berdasarkan *gradient boosting framework* dengan tujuan meningkatkan akurasi prediksi melalui perbaikan bertahap terhadap kesalahan model sebelumnya. Algoritma ini mengadopsi pendekatan *ensemble*, di mana setiap pohon keputusan yang dibangun berfungsi untuk memperbaiki *residual* atau kesalahan prediksi yang dihasilkan oleh pohon-pohon pada tahapan sebelumnya [16]. Algoritma ini dirancang untuk bekerja secara efisien melalui optimasi komputasi, regularisasi yang kuat, serta kemampuan menangani data berskala besar sehingga dapat meminimalkan risiko *overfitting* [17]. Proses pembelajaran XGBoost berfokus pada minimisasi *loss function*, yang digunakan untuk mengevaluasi kualitas struktur pohon yang dihasilkan. Dengan mengiterasikan pembentukan pohon yang dapat menurunkan nilai *loss function*, XGBoost mampu menghasilkan model klasifikasi yang lebih stabil, akurat, dan optimal [14]. Persamaan dari XGBoost ditunjukkan pada pers. (5).

$$L(\phi) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k), \quad (5)$$

dengan

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2. \quad (6)$$

Persamaan tersebut merupakan fungsi objektif yang dilengkapi dengan regularisasi. Komponen *loss* $l(\hat{y}_i, y_i)$ digunakan untuk mengukur kesalahan prediksi terhadap nilai sebenarnya, sedangkan komponen regularisasi $\Omega(f)$ berperan sebagai penalti untuk membatasi kompleksitas model agar tidak menjadi terlalu rumit dan menjaga kestabilan bobot model sehingga tidak mudah mengalami *overfitting* [14].

2.6. Artificial Neural Network (ANN)

Artificial Neural Network (ANN) juga dikenal dengan Jaringan Syaraf Tiruan, merupakan suatu metode, teknik, atau pendekatan yang terinspirasi dari prinsip kerja sistem jaringan saraf biologis manusia dalam memproses suatu informasi. Secara konseptual, ANN mengadopsi prinsip kerja neuron biologis yang terdiri dari tiga komponen utama: dendrit (penerima sinyal), soma (badan sel pemroses), dan akson (pengirim sinyal) [18]. Struktur ini direpresentasikan menjadi tiga lapisan utama yaitu: *Input Layer*, *Hidden Layer*, dan *Output Layer*. *Input Layer* berfungsi sebagai penerima data awal yang merepresentasikan variabel-variabel fitur. *Hidden Layer* yaitu lapisan di mana proses komputasi utama terjadi. Pada lapisan ini, informasi diproses melalui pembobotan (*weighting*) dan fungsi aktivasi untuk mengekstrak fitur non-linear. *Output Layer* menghasilkan hasil prediksi atau klasifikasi akhir berdasarkan hasil pemrosesan dari lapisan sebelumnya [19, 20]. Kinerja ANN dievaluasi menggunakan akurasi, *balanced accuracy*, sensitivitas, spesifisitas, dan *PR-AUC* berdasarkan skema *stratified 10-fold cross-validation*. Output dari neuron k pada lapisan tertentu dapat dirumuskan pada pers. (7).

$$y_k = \phi \left(\sum_{i=1}^n w_{ki} x_i + b_k \right). \quad (7)$$

Fungsi aktivasi $\phi(\cdot)$ berperan krusial dalam memperkenalkan non-linearitas ke dalam jaringan, sehingga model dapat mempelajari pola data yang kompleks. Salah satu fungsi aktivasi yang umum digunakan dalam klasifikasi biner pada lapisan output adalah fungsi *sigmoid* yang dinyatakan dengan pers. (8).

$$\sigma(z) = \frac{1}{1 + e^{-z}}. \quad (8)$$

Proses pelatihan (*training*) pada ANN bertujuan untuk meminimalkan *error* atau kesalahan prediksi. Jika menggunakan metode *Backpropagation*, algoritma akan menghitung selisih antara hasil prediksi (y) dengan target aktual (t). Fungsi kerugian (*loss function*) yang umum digunakan, seperti *Mean Squared Error* (MSE), dihitung dengan pers. (9).

$$E = \frac{1}{2} \sum_k (t_k - y_k)^2. \quad (9)$$

Nilai *error* (E) ini kemudian digunakan untuk memperbarui bobot (w) dan bias (b) secara iteratif menggunakan metode *Gradient Descent* agar performa model semakin akurat pada iterasi berikutnya.

Tabel 2. *Confusion Matrix*

Kelas Aktual	Kelas Prediksi	
	Rawan	Aman
Rawan	TP	FN
Aman	FP	TN

2.7. Evaluasi Kinerja Model

Hasil prediksi dalam pemodelan klasifikasi tidak selalu sesuai dengan kondisi sebenarnya, sehingga diperlukan evaluasi untuk menilai kinerja model. Salah satu metode evaluasi yang paling umum digunakan adalah *confusion matrix*, yaitu tabel yang membandingkan antara kelas aktual dan kelas yang diprediksi oleh model. Pada kasus klasifikasi biner, *confusion matrix*

terdiri dari empat komponen utama, yaitu: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) [18]. Tabel 2 merupakan *confusion matrix* yang digunakan untuk mengevaluasi model.

Berdasarkan *confusion matrix*, metrik evaluasi yang digunakan dalam menilai performa model klasifikasi antara lain:

1. Akurasi

Akurasi mengukur seberapa banyak prediksi model sesuai dengan kondisi sebenarnya pada seluruh data, yang dihitung dengan menggunakan pers. (10).

$$\text{Akurasi} = \frac{TN + TP}{TN + FP + FN + TP}. \quad (10)$$

2. Sensitivitas

Sensitivitas menunjukkan kemampuan model dalam mengenali kasus positif dengan benar dari seluruh data, yang nilainya ditentukan dengan menggunakan pers. (11).

$$\text{Sensitivitas} = \frac{TP}{FN + TP}. \quad (11)$$

3. Spesifisitas

Spesifisitas mengukur kemampuan model dalam mengenali kasus negatif dengan benar dari seluruh data, yang ditetapkan dengan menggunakan pers. (12).

$$\text{Spesifisitas} = \frac{TN}{TN + FP}. \quad (12)$$

4. *Balanced Accuracy*

Balanced Accuracy menunjukkan ukuran yang lebih seimbang ketika kelas pada data tidak proporsional. Nilai ini merupakan rata-rata dari sensitivitas dan spesifisitas, yang ditentukan dengan menggunakan pers. (13).

$$\text{Balanced Accuracy} = \frac{\text{Sensitivitas} + \text{Spesifisitas}}{2}. \quad (13)$$


3. Hasil dan Pembahasan

Bagian ini menyajikan hasil eksplorasi data serta pemodelan klasifikasi yang mencakup pemilihan model terbaik dan evaluasi performa model.

3.1. Eksplorasi Data

Sebelum melakukan analisis lebih lanjut, dilakukan eksplorasi awal untuk memperoleh gambaran umum dari dataset kondisi ketahanan pangan rumah tangga di Provinsi Jawa Barat berdasarkan indikator *Food Insecurity Experience Scale* (FIES). Penelitian ini menggunakan variabel respon dari kategori biner yang terdiri dari 2 kelas yaitu: Rawan Pangan dan Aman Pangan dari skor FIES yang berjumlah 26.012 data rumah tangga yang menggambarkan variasi kondisi ketahanan pangan pada tingkat rumah tangga.


Gambar 1 menunjukkan distribusi kategori FIES pada dataset tahun 2023 di Provinsi Jawa Barat. Hasil menunjukkan bahwa sebanyak 1.853 rumah tangga (7,1%) berada dalam kondisi Rawan Pangan, sedangkan 24.159 rumah tangga (92,9%) termasuk dalam kategori Aman Pangan. Proporsi yang timpang ini mengindikasikan bahwa sebagian besar rumah tangga di Provinsi Jawa Barat relatif tidak mengalami gangguan ketahanan pangan yang signifikan. Namun, ketidakseimbangan distribusi kelas berpotensi menimbulkan bias klasifikasi, khususnya



Gambar 1. Distribusi variabel respon

kecenderungan model untuk lebih akurat memprediksi kelas mayoritas. Oleh karena itu, kelompok rumah tangga rawan pangan tetap penting untuk dianalisis secara mendalam guna mengidentifikasi faktor-faktor yang berkontribusi terhadap kerentanan pangan di Provinsi Jawa Barat serta memastikan kinerja model yang lebih seimbang.

Selanjutnya, dilakukan eksplorasi data terhadap 14 variabel prediktor (X1–X14) untuk mengetahui hubungan setiap variabel dengan status ketahanan pangan.

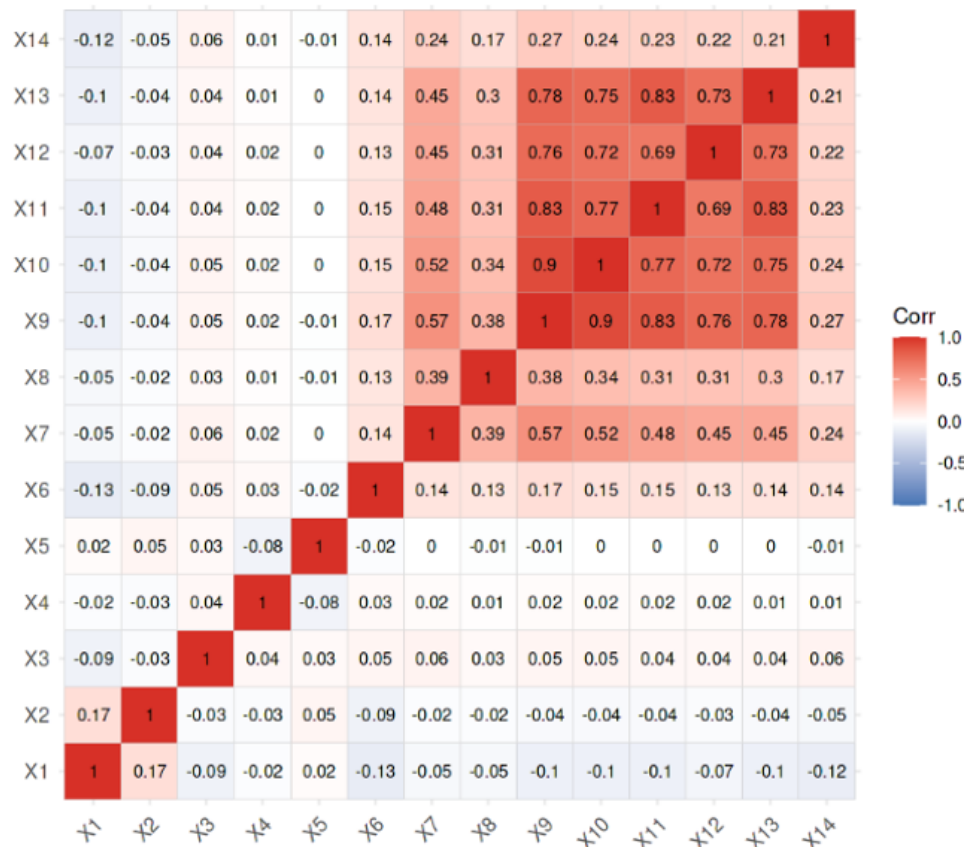


Gambar 2. Proporsi Rumah Tangga

Gambar 2 menunjukkan proporsi rumah tangga Rawan Pangan dan Aman Pangan berdasarkan 14 variabel prediktor biner (X1–X14). Secara umum, kategori Aman Pangan tetap mendominasi pada seluruh variabel, namun terdapat beberapa kategori yang memperlihatkan proporsi Rawan Pangan yang lebih tinggi. Proporsi kerawanan pangan tampak meningkat pada rumah tangga yang mengalami kekurangan air (X4) serta pada kelompok penerima ban-

tuan pangan (X10–X14). Sebaliknya, variabel yang berkaitan dengan kondisi ekonomi (X6) menunjukkan kecenderungan lebih besar pada kelompok Aman Pangan. Temuan eksploratif ini memberikan indikasi awal bahwa setiap variabel memiliki kontribusi yang berbeda terhadap tingkat kerawanan pangan.

Selanjutnya, dilakukan analisis korelasi untuk memahami hubungan antar variabel prediktor yang digunakan dalam penelitian ini.



Gambar 3. Matriks korelasi variabel prediktor

Gambar 3 menampilkan matriks korelasi antar variabel yang digunakan dalam analisis. Secara umum, sebagian besar pasangan variabel menunjukkan nilai korelasi di bawah 0,7, sehingga risiko multikolinieritas yang mengkhawatirkan relatif kecil. Korelasi yang lebih tinggi terutama terlihat pada variabel bantuan pangan (X10–X14), yang menggambarkan konsistensi penerimaan Bantuan Pangan Non Tunai (BPNT) pada beberapa periode berturut-turut. Sementara itu, variabel terkait akses dan kualitas air (X2, X3, dan X5) serta variabel sosial-ekonomi seperti X6 menunjukkan korelasi yang lemah satu sama lain; hal ini menandakan bahwa setiap variabel memberikan informasi yang berbeda. Pola ini menunjukkan bahwa kerawanan pangan bersifat multidimensional dengan struktur hubungan yang kompleks dan tidak sepenuhnya linier, serta melibatkan interaksi faktor ekonomi, sosial, dan lingkungan. Oleh karena itu, seluruh variabel prediktor dipertahankan dalam pemodelan, karena algoritma *machine learning* berbasis pohon dan jaringan saraf relatif *robust* terhadap korelasi antarprediktor.

3.2. Random Forest

Salah satu kelebihan penting dari *Random Forest* adalah kemampuan dalam menghasilkan estimasi *Variable Importance*, yakni ukuran yang menggambarkan seberapa besar peran tiap variabel dalam meningkatkan akurasi prediksi. Dalam penelitian ini, *Random Forest* digunak-

an untuk mengidentifikasi variabel yang memberikan kontribusi paling signifikan terhadap proses klasifikasi melalui nilai *Variable Importance* yang diperoleh. Variabel dengan nilai kepentingan tinggi dianggap memiliki peranan lebih besar dalam membentuk keputusan model, sehingga dapat menjadi dasar dalam interpretasi hasil serta pertimbangan penyusunan kebijakan atau intervensi yang relevan [11]. Hasil *Variable Importance Random Forest* dapat dilihat pada Tabel 3.

Tabel 3. Hasil *Variable Importance* 4 Variabel Teratas *Random Forest*

Kategori	Variabel	Nilai
Ekonomi	Indeks Kekayaan	100
Sosial	Penerima Bantuan Beras	78,0
Lingkungan	Tipe Wilayah	55,0
Sosial	Belanja Pangan	50,0

Tabel 3 menunjukkan bahwa variabel dengan kontribusi paling tinggi terhadap prediksi model adalah Indeks Kekayaan (X6) yang mewakili faktor ekonomi. Nilai *importance* yang paling besar menunjukkan bahwa kondisi ekonomi rumah tangga menjadi faktor dominan dalam membedakan status kerawanan pangan, sehingga indeks kekayaan berperan sebagai variabel kunci dalam model.

Pada kategori sosial dan lingkungan, variabel Penerima Bantuan Beras (X14) dan Tipe Wilayah (X1) menempati posisi berikutnya. Nilai *importance* yang cukup tinggi dari X14 menunjukkan bahwa keterlibatan rumah tangga dalam program bantuan pangan memiliki pengaruh signifikan terhadap ketahanan pangan, sedangkan X1 mengindikasikan bahwa perbedaan karakteristik wilayah turut memengaruhi kondisi kerawanan pangan.

Setelah diperoleh nilai *variable importance* dari variabel yang digunakan, tahap selanjutnya adalah mengevaluasi performa model untuk menilai kemampuan generalisasinya. Evaluasi dilakukan dengan membandingkan kinerja model pada data *training* dan *testing* berdasarkan tiga teknik penyeimbangan data, yaitu *Base*, *Undersampling*, dan *SMOTE*. Hasil evaluasi performa model *Random Forest* ditampilkan pada Tabel 4.

Tabel 4. Evaluasi Performa Model *Random Forest*

Metrik	Base		Undersampling		SMOTE	
	Training	Testing	Training	Testing	Training	Testing
Akurasi	0,924	0,918	0,701	0,634	0,753	0,707
Sensitivitas	0,070	0,039	0,694	0,701	0,701	0,671
Spesifisitas	0,960	0,971	0,688	0,628	0,686	0,663
<i>Balanced Accuracy</i>	0,515	0,505	0,691	0,665	0,693	0,671

Pada data *testing*, model *Base* memang menunjukkan akurasi tertinggi (0,918), namun sensitivitasnya sangat rendah (0,039), yang menunjukkan bahwa model hampir mengabaikan kelas rawan pangan. Skenario *Undersampling* meningkatkan sensitivitas secara signifikan menjadi 0,701, tetapi akurasi turun menjadi 0,634 karena hilangnya sebagian besar informasi dari kelas mayoritas. Pendekatan *SMOTE* menghasilkan performa paling seimbang dengan sensitivitas 0,671, spesifisitas 0,663, dan *balanced accuracy* tertinggi (0,671). Nilai metrik antara data *training* dan *testing* juga relatif konsisten sehingga tidak menunjukkan *overfitting*. Dengan demikian, *SMOTE* merupakan metode paling optimal untuk mengatasi ketidakseimbangan data pada model *Random Forest* dalam penelitian ini karena mampu meningkatkan deteksi kelas minoritas tanpa mengorbankan performa kelas mayoritas secara berlebihan.

3.3. Light Gradient Boosting Machine (LightGBM)

Metode *Light Gradient Boosting Machine* (LightGBM) mampu memberikan kinerja unggulan dalam berbagai aplikasi klasifikasi multi-kategori [20], perkiraan probabilitas klik, serta algoritma *learning to rank* [21]. Salah satu keunggulan utama LightGBM adalah kemampuannya dalam menghasilkan *variable importance*, yaitu ukuran yang menunjukkan besarnya kontribusi setiap variabel terhadap peningkatan kinerja model.

Dalam penelitian ini, LightGBM digunakan untuk mengidentifikasi variabel-variabel yang memberikan kontribusi paling signifikan terhadap hasil prediksi melalui estimasi *variable importance*. Nilai kepentingan yang tinggi mengindikasikan bahwa variabel tersebut memiliki pengaruh dominan dalam membentuk output klasifikasi, sehingga dapat dijadikan dasar dalam proses interpretasi hasil maupun penyusunan rekomendasi kebijakan atau intervensi yang relevan [13]. Hasil *variable importance* model LightGBM disajikan pada Tabel 5.

Tabel 5. Hasil *Variable Importance* Empat Variabel Teratas LightGBM

Kategori	Variabel	Nilai
Ekonomi	Indeks Kekayaan	100
Lingkungan	Sumber Air Minum	61,40
Sosial	Penerima Bantuan Beras	27,70
Lingkungan	Tipe Wilayah	25,00

Hasil *variable importance* dari LightGBM yang dihitung berdasarkan nilai *gain* menunjukkan bahwa Indeks Kekayaan merupakan variabel yang paling dominan dalam menjelaskan variasi tingkat kerawanan pangan di Jawa Barat. Variabel Sumber Air Minum dan Penerima Bantuan Beras juga menunjukkan pengaruh yang cukup signifikan sebagai faktor pendukung utama dalam model. Sementara itu, Tipe Wilayah memiliki kontribusi yang lebih kecil dibandingkan variabel lainnya, namun tetap memberikan informasi yang penting bagi proses klasifikasi. Secara keseluruhan, temuan ini mengindikasikan bahwa aspek ekonomi, kondisi lingkungan, dan dukungan sosial merupakan faktor-faktor kunci yang membentuk tingkat kerawanan pangan di wilayah Jawa Barat.

Selain itu, kontribusi tiap variabel dalam model LightGBM berkaitan langsung dengan proses yang dijelaskan melalui pers. (3) dan pers. (4). Melalui pers. (3), fungsi *sigmoid* mengubah output model menjadi probabilitas antara 0 dan 1, sehingga setiap variabel berkontribusi terhadap besarnya perubahan probabilitas kejadian kelas 1. Probabilitas ini kemudian digunakan untuk menentukan kelas prediksi sesuai aturan pada pers. (4), yaitu apakah nilai probabilitas melewati ambang 0,5 atau tidak.

Selanjutnya, peran setiap variabel dalam memperbaiki prediksi dievaluasi menggunakan pengukur kesalahan prediksi *log-loss* pada pers. (3), di mana variabel yang mampu mengurangi nilai *log-loss* secara signifikan akan memperoleh nilai *variable importance* yang lebih tinggi. Dengan demikian, *variable importance* yang dihasilkan LightGBM tidak hanya menggambarkan pengaruh variabel terhadap struktur pohon keputusan, tetapi juga menunjukkan kontribusinya dalam menurunkan kesalahan prediksi.

Setelah model LightGBM dikonstruksi, dilakukan evaluasi performa untuk memastikan kemampuan model dalam melakukan klasifikasi secara konsisten dan akurat. Proses evaluasi ini bertujuan untuk menilai keandalan model saat diaplikasikan pada data yang tidak digunakan dalam pelatihan. Ringkasan hasil evaluasi performa LightGBM disajikan pada Tabel 6.

Hasil evaluasi menunjukkan bahwa performa model berbeda cukup signifikan antar skenario. Pada data *training*, skenario *undersampling* memberikan kinerja tertinggi dengan aku-

Tabel 6. Evaluasi Performa Model LightGBM

Metrik	Base		Undersampling		SMOTE	
	Training	Testing	Training	Testing	Training	Testing
Akurasi	0,741	0,524	0,795	0,561	0,747	0,685
Sensitivitas	0,786	0,821	0,811	0,767	0,773	0,641
Spesifisitas	0,737	0,501	0,779	0,544	0,745	0,688
Balanced Accuracy	0,762	0,661	0,795	0,656	0,759	0,665

rasi 0,795, sensitivitas 0,811, spesifisitas 0,779, dan *balanced accuracy* sebesar 0,795. Namun, performa yang sangat tinggi pada data *training* tidak diikuti oleh performa serupa pada data *testing*, sehingga mengindikasikan terjadinya *overfitting*. Pada data *testing*, skenario SMOTE menghasilkan performa paling seimbang dengan akurasi 0,685, sensitivitas 0,641, spesifisitas 0,688, dan *balanced accuracy* sebesar 0,665. Meskipun nilainya tidak setinggi skenario *undersampling* pada data *training*, model ini memiliki kemampuan generalisasi (*generalizability*) terbaik karena menunjukkan kinerja yang lebih stabil pada data *testing*. Skenario *base* menunjukkan sensitivitas tertinggi pada data *testing* (0,821), tetapi memiliki spesifisitas yang sangat rendah (0,501), sehingga cenderung bias terhadap kelas positif. Hal ini menyebabkan nilai *balanced accuracy* pada skenario *base* hanya sebesar 0,661, yang lebih rendah dibandingkan dengan skenario SMOTE.

Secara keseluruhan, skenario SMOTE dipilih sebagai model paling optimal karena mampu mempertahankan kinerja yang lebih konsisten antara data *training* dan *testing*, serta memberikan nilai *balanced accuracy* tertinggi pada data *testing* (0,665), yang menjadi indikator utama dalam kondisi distribusi kelas tidak seimbang.

3.4. Extreme Gradient Boosting (XGBoost)

Metode *Extreme Gradient Boosting* (XGBoost) mengidentifikasi variabel yang memberikan kontribusi paling besar dalam proses klasifikasi melalui nilai *variable importance*. Variabel dengan nilai kepentingan tinggi dianggap berperan lebih besar dalam menurunkan kesalahan prediksi serta meningkatkan stabilitas model. Hasil *variable importance* model XGBoost ditampilkan pada **Tabel 7**.

Tabel 7. Hasil *Variable Importance* Empat Variabel Teratas XGBoost

Kategori	Variabel	Nilai
Ekonomi	Indeks Kekayaan	44,9
Lingkungan	Tipe Wilayah	8,8
Sosial	Penerima Bantuan Beras	7,6
Sosial	Penerima KKS	5,1

Hasil *variable importance* XGBoost menunjukkan bahwa Indeks Kekayaan merupakan variabel dengan pengaruh terbesar terhadap klasifikasi kerawanan pangan, dengan nilai kepentingan sebesar 44,9 yang berasal dari total *gain* pada seluruh pohon dalam model. Temuan ini menegaskan bahwa kondisi ekonomi menjadi faktor utama yang membedakan rumah tangga rawan pangan dari yang aman pangan. Variabel Tipe Wilayah serta indikator bantuan sosial seperti Penerima Bantuan Beras dan Penerima Kartu Keluarga Sejahtera (KKS) juga memberikan kontribusi terhadap model, meskipun dengan tingkat pengaruh yang lebih rendah. Secara keseluruhan, hasil ini mengindikasikan bahwa aspek ekonomi, karakteristik lingkungan tempat tinggal, dan akses terhadap bantuan sosial merupakan komponen penting yang memengaruhi

tingkat kerawanan pangan di Provinsi Jawa Barat.

Setelah diperoleh *variable importance* dari variabel yang digunakan, proses selanjutnya adalah mengevaluasi performa model XGBoost untuk menilai kemampuan generalisasi model. Evaluasi dilakukan dengan membandingkan kinerja pada data *training* dan *testing* berdasarkan tiga teknik penyeimbangan data, yaitu *base*, *undersampling*, dan SMOTE. Perbandingan ini bertujuan untuk memastikan bahwa model tidak hanya berkinerja baik pada data latih, tetapi juga mampu melakukan klasifikasi secara akurat pada data baru. Hasil evaluasi performa model XGBoost ditampilkan pada **Tabel 8**.

Tabel 8. Evaluasi Performa Model XGBoost

Metrik	Base		Undersampling		SMOTE	
	Training	Testing	Training	Testing	Training	Testing
Akurasi	0,722	0,710	0,721	0,709	0,722	0,711
Sensitivitas	0,735	0,722	0,734	0,721	0,734	0,722
Spesifisitas	0,548	0,551	0,549	0,554	0,547	0,559
Balanced Accuracy	0,642	0,637	0,641	0,638	0,641	0,640

Berdasarkan hasil evaluasi pada **Tabel 8**, skenario SMOTE merupakan konfigurasi XGBoost dengan performa terbaik pada data *training* dan *testing*. Hal ini disebabkan oleh kemampuan SMOTE dalam memperluas representasi kelas minoritas sehingga model XGBoost dapat mempelajari pola keputusan secara lebih optimal. Skenario ini menghasilkan akurasi sebesar 0,711, sensitivitas 0,722, spesifisitas 0,559, serta *balanced accuracy* sebesar 0,640 yang merupakan nilai tertinggi dibandingkan skenario *base* dan *undersampling*.

Selain itu, perbedaan kinerja antara data *training* dan *testing* pada skenario SMOTE relatif kecil, yang mengindikasikan bahwa model tidak mengalami *overfitting* dan memiliki kemampuan generalisasi yang baik. Dengan capaian akurasi, sensitivitas, spesifisitas, dan *balanced accuracy* yang relatif lebih tinggi dibandingkan dua skenario lainnya, SMOTE dapat dianggap sebagai konfigurasi paling optimal untuk model XGBoost dalam menangani data dengan distribusi kelas yang tidak seimbang.

3.5. Artificial Neural Network (ANN)

Tahap selanjutnya dalam penelitian ini adalah konstruksi dan evaluasi model *Artificial Neural Network* (ANN) untuk klasifikasi kerawanan pangan rumah tangga. Model ANN yang digunakan merupakan *Multilayer Perceptron* (MLP) dengan arsitektur satu lapisan input, satu lapisan tersembunyi (*hidden layer*), dan satu lapisan output. Lapisan input menerima seluruh variabel prediktor hasil *preprocessing*, sedangkan lapisan tersembunyi terdiri dari 4 hingga 16 neuron. Fungsi aktivasi yang digunakan pada lapisan tersembunyi adalah *sigmoid* (*logistic*), sesuai dengan implementasi standar pada algoritma ANN berbasis *engine nnet*. Lapisan output terdiri dari satu neuron dengan fungsi aktivasi *sigmoid* untuk menghasilkan probabilitas klasifikasi biner. Proses pelatihan ANN dilakukan menggunakan algoritma *backpropagation* dengan optimisasi berbasis *gradient descent*. Untuk mengendalikan kompleksitas model dan mencegah *overfitting*, diterapkan regularisasi L2 (*weight decay*) yang dioptimalkan melalui proses *tuning*. Jumlah *epoch* pelatihan juga ditentukan secara adaptif dalam rentang 50–150 *epoch*. Parameter *learning rate* dan *batch size* tidak diatur secara eksplisit, melainkan mengikuti pengaturan internal dari algoritma optimisasi pada *engine* tersebut.

ANN tidak memiliki mekanisme bawaan untuk menghasilkan *variable importance* karena bobot model tersebar secara nonlinier pada banyak neuron dan lapisan. Oleh karena itu, in-

terpretasi ANN memerlukan pendekatan khusus yang bersifat *model-agnostic*. Dalam konteks ini, *permutation importance* dipilih karena metode ini mengukur kontribusi variabel berdasarkan perubahan kinerja prediksi model ketika nilai suatu variabel diacak tanpa bergantung pada cara kerja atau susunan perhitungan di dalam model. Hasil *variable importance* model ANN ditampilkan pada **Tabel 9**.

Tabel 9. Hasil *Variable Importance* 4 Variabel Teratas ANN

Kategori	Variabel	Nilai
Sosial	Penerima BPNT	28,5
Sosial	Penggunaan BPNT	15,8
Lingkungan	Kondisi Fisik Air	13,4
Ekonomi	Indeks Kekayaan	7,8

Hasil *variable importance* dari model *Artificial Neural Network* (ANN) dengan menggunakan metode *permutation importance* menunjukkan bahwa Penerima BPNT memiliki kontribusi terbesar terhadap model dengan nilai 28,5, menandakan bahwa faktor sosial, khususnya penerimaan bantuan pangan, memainkan peran penting dalam menentukan kerawanan pangan. Penggunaan BPNT dan Kualitas Air juga memiliki pengaruh signifikan dengan nilai 15,8 dan 13,4 berturut-turut, yang menunjukkan bahwa akses terhadap bantuan sosial serta kualitas sumber air mempengaruhi tingkat kerawanan pangan rumah tangga. Selain itu, Indeks Kekayaan dengan nilai 7,8, serta variabel lainnya seperti Tipe Wilayah, Program Keluarga Harapan (PKH): Belanja Pangan, Sumber Air, dan Penerima Bantuan Beras turut memberikan kontribusi meskipun lebih rendah. Temuan ini menegaskan bahwa faktor sosial, ekonomi, dan kondisi lingkungan seperti kualitas air, serta akses terhadap bantuan pangan tetap menjadi faktor dominan dalam membedakan rumah tangga rawan dan aman pangan.

Tabel 10. Evaluasi Performa Model ANN

Metrik	Base		Undersampling		SMOTE	
	Training	Testing	Training	Testing	Training	Testing
Akurasi	0,930	0,915	0,505	0,505	0,681	0,677
Sensitivitas	0,025	0,018	0,641	0,62	0,633	0,631
Spesifisitas	0,998	0,999	0,799	0,72	0,685	0,688
Balanced Accuracy	0,511	0,509	0,641	0,62	0,659	0,655

Berdasarkan hasil evaluasi pada **Tabel 10**, terlihat bahwa skenario SMOTE merupakan konfigurasi model ANN dengan performa terbaik pada data testing. Skenario ini menghasilkan akurasi 0,677, sensitivitas 0,631, spesifisitas 0,680, serta *balanced accuracy* sebesar 0,655. Analisis performa menunjukkan bahwa model ANN pada skenario Base menunjukkan akurasi yang sangat tinggi (0,915), namun nilai sensitivitasnya sangat rendah (0,018) dengan *balanced accuracy* mendekati nilai acak (0,509). Hal ini mengindikasikan bahwa model ANN pada data asli mengalami bias yang ekstrim terhadap kelas mayoritas. Penerapan teknik SMOTE berhasil menanggulangi bias tersebut. Nilai *balanced accuracy* pada skenario SMOTE (0,655) menjadi yang tertinggi dibandingkan dengan Base (0,509) dan Undersampling (0,505).

Meskipun demikian, model ANN menunjukkan akurasi dan *balanced accuracy* yang secara umum lebih rendah dibandingkan dengan model *Gradient Boosting* seperti XGBoost dan LightGBM (yang mencapai *balanced accuracy* di atas 0,640). Pada skenario SMOTE, perbedaan performa antara data training (*balanced accuracy* 0,659) dan testing (0,655) relatif kecil, yang menandakan bahwa model cukup stabil dalam generalisasi dan tidak mengalami *overfitting*.

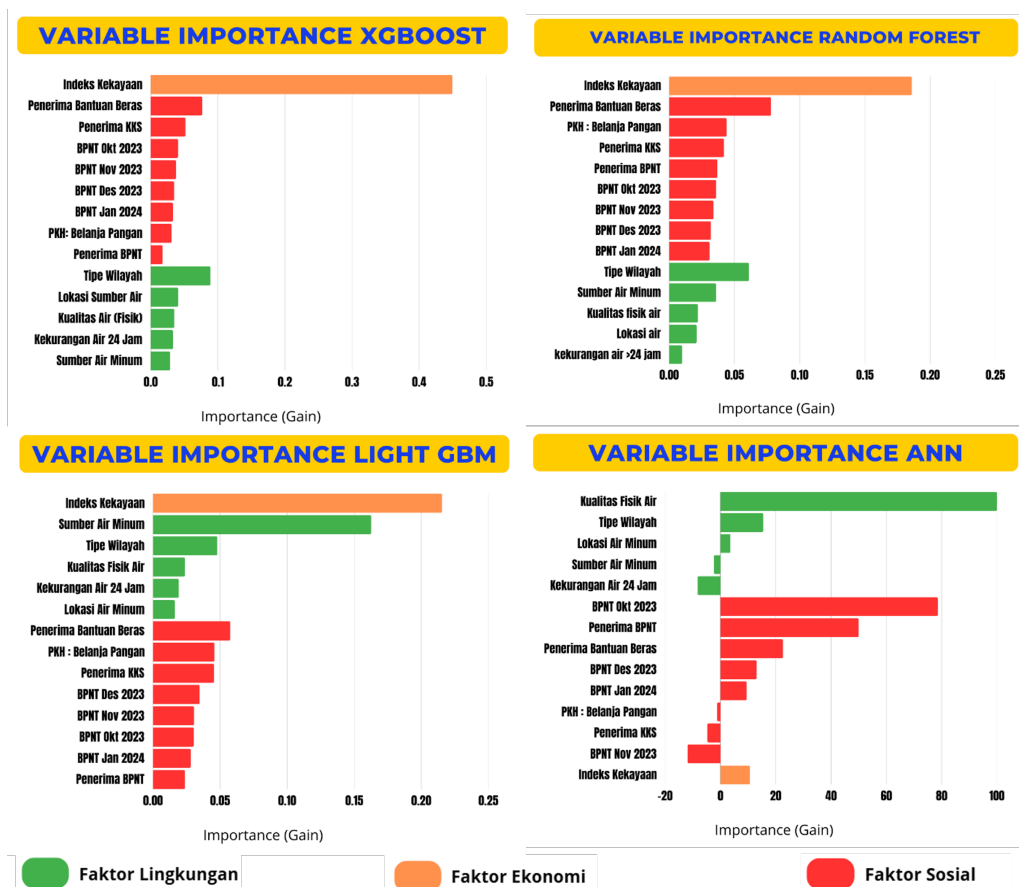
yang signifikan. Dengan *balanced accuracy* tertinggi, skenario SMOTE dipilih sebagai model ANN paling optimal untuk klasifikasi kerawanan pangan. Hal ini menunjukkan bahwa ANN lebih sulit dilatih pada data tabular nonlinier dengan fitur terbatas.

3.6. Perbandingan Keempat Metode

3.6.1. Identifikasi Faktor Berpengaruh

Berdasarkan hasil analisis *variable importance* dari *Random Forest*, *LightGBM*, *XGBoost*, dan ANN, terlihat adanya pola yang relatif konsisten dalam mengidentifikasi variabel-variabel utama yang memengaruhi kerawanan pangan di Provinsi Jawa Barat. Variabel Indeks Kekayaan secara konsisten muncul sebagai prediktor paling dominan pada model berbasis pohon, yang menegaskan bahwa kondisi ekonomi rumah tangga merupakan faktor utama dalam membedakan rumah tangga rawan dan aman pangan.

Selain faktor ekonomi, variabel yang berkaitan dengan akses terhadap air minum juga menunjukkan tingkat kepentingan yang relatif tinggi, mengindikasikan bahwa keterbatasan akses terhadap air layak berkontribusi terhadap meningkatnya risiko kerawanan pangan. Variabel tipe wilayah memiliki pengaruh menengah, sementara variabel bantuan sosial cenderung berperan sebagai faktor mitigasi, bukan sebagai pembeda utama dalam proses klasifikasi. Berbeda dengan model berbasis pohon, ANN menunjukkan pola *variable importance* yang lebih menonjol pada variabel sosial dan lingkungan, yang mencerminkan kemampuannya dalam menangkap hubungan nonlinier serta interaksi kompleks antar variabel. Hasil analisis ini ditunjukkan pada Gambar 4.



Gambar 4. Skor Tingkat Kepentingan Variabel Prediktor Hasil Perhitungan Empat Model Pembelajaran Mesin (XGBoost, Random Forest, LightGBM, dan ANN)

Secara keseluruhan, temuan ini menunjukkan bahwa faktor ekonomi dan lingkungan merupakan faktor utama dalam kerawanan pangan yang secara konsisten teridentifikasi oleh berbagai model. Faktor sosial berperan sebagai elemen pendukung yang dapat memperkuat atau memperlemah tingkat kerentanan rumah tangga dalam kondisi tertentu. Model *boosting* menangkap interaksi non-linear antara kekayaan dan akses air, yang tidak terlihat pada analisis eksploratif awal.

3.6.2. Hasil Evaluasi Performa

Untuk memperoleh gambaran komprehensif mengenai keunggulan relatif masing-masing algoritma, dilakukan perbandingan kinerja berdasarkan metrik evaluasi utama pada skenario terbaik yang dihasilkan oleh setiap model sebagaimana disajikan pada **Tabel 11**.

Tabel 11. Perbandingan Evaluasi Performa

Algoritma	Skenario Terbaik	Akurasi	Balanced Accuracy	Sensitivitas	Spesifisitas
Random Forest	SMOTE	0,707	0,672	0,631	0,663
LightGBM	SMOTE	0,685	0,665	0,641	0,688
XGBoost	SMOTE	0,711	0,640	0,722	0,559
ANN	SMOTE	0,677	0,655	0,631	0,680

Berdasarkan evaluasi performa pada **Tabel 11** yang menyajikan skenario terbaik dari masing-masing algoritma, seluruh model mencapai kinerja optimal ketika dikombinasikan dengan teknik SMOTE. Temuan ini menegaskan bahwa penanganan ketidakseimbangan kelas merupakan faktor krusial dalam meningkatkan performa model klasifikasi kerawanan pangan. Pada kondisi terbaik tersebut, XGBoost menunjukkan akurasi tertinggi (0,711) serta sensitivitas terbaik (0,722), yang mengindikasikan kemampuan paling efektif dalam mendeteksi rumah tangga rawan pangan. Sementara itu, Random Forest memiliki nilai *balanced accuracy* tertinggi (0,672), yang mencerminkan keseimbangan prediksi terbaik antara kelas rawan dan aman pangan. LightGBM unggul pada metrik spesifisitas (0,688), menunjukkan performa terbaik dalam mengidentifikasi rumah tangga tidak rawan pangan, sedangkan ANN menunjukkan performa yang relatif lebih rendah namun tetap stabil setelah penanganan ketidakseimbangan kelas.

Hasil perbandingan pada skenario terbaik menunjukkan bahwa masing-masing algoritma memiliki karakteristik kinerja yang berbeda. Oleh karena itu, pemilihan model perlu disesuaikan dengan tujuan analisis, khususnya dalam mendeteksi rumah tangga rawan pangan maupun dalam menjaga keseimbangan prediksi antar kelas. *Confusion matrix* dari skenario XGBoost dengan teknik SMOTE sebagai model paling optimal disajikan pada **Tabel 12**.

Tabel 12. *Confusion Matrix* Skenario Terbaik

Kelas Aktual	Kelas Prediksi	
	Rawan	Aman
Rawan	212	1339
Aman	167	3485

Berdasarkan *confusion matrix* pada **Tabel 12** diketahui bahwa model XGBoost berhasil mengklasifikasikan 212 rumah tangga rawan pangan secara benar (*true positive*), sementara 167 rumah tangga rawan pangan masih salah diprediksi sebagai aman (*false negative*). Pada kelas aman pangan, terdapat 3.485 rumah tangga yang teridentifikasi dengan tepat (*true negative*), sedangkan 1.339 rumah tangga salah diklasifikasikan sebagai rawan (*false positive*). Hasil

ini menunjukkan bahwa meskipun kemampuan deteksi terhadap rumah tangga rawan pangan tergolong baik, masih terdapat kesalahan prediksi pada kelas aman pangan yang mencerminkan adanya *trade-off* antara kedua kelas, sehingga peningkatan kinerja model dalam mendeteksi rumah tangga rawan pangan diikuti oleh meningkatnya kesalahan prediksi pada kelas aman pangan.

4. Kesimpulan

Berdasarkan hasil *variable importance*, model berbasis pohon (*Random Forest*, *XGBoost*, dan *LightGBM*) secara konsisten mengidentifikasi Indeks Kekayaan Rumah Tangga sebagai determinan paling kuat kerawanan pangan, menegaskan pentingnya intervensi berbasis peningkatan kapasitas ekonomi rumah tangga rentan. Variabel akses sumber air minum dan penerimaan bantuan pangan juga berkontribusi penting yang menunjukkan bahwa akses air bersih berhubungan dengan stabilitas konsumsi pangan, sedangkan bantuan sosial menjadi indikator kerentanan awal. Di sisi lain, model ANN menunjukkan pola berbeda dengan menempatkan variabel bantuan sosial dan kondisi air sebagai prediktor yang lebih dominan, mengindikasikan sensitivitas ANN terhadap hubungan non-linier dan interaksi kompleks antarvariabel.

Dari sisi kinerja model, *XGBoost* menghasilkan akurasi tertinggi (0,711), sedangkan *Random Forest* menunjukkan *balanced accuracy* yang lebih baik (0,672), sehingga keduanya saling melengkapi dalam konteks data tidak seimbang. Secara praktis, temuan ini mendukung perlunya kebijakan ketahanan pangan yang terpadu, dengan fokus pada peningkatan kesejahteraan ekonomi, perbaikan akses air bersih, dan penajaman sasaran program bantuan pangan. Temuan ini dapat digunakan pemerintah daerah untuk penargetan bantuan berbasis indikator ekonomi dan akses air.

Penelitian ini memiliki keterbatasan karena hanya menggunakan variabel SUSENAS dan belum mempertimbangkan dimensi spasial maupun temporal. Penelitian selanjutnya disarankan mengembangkan pendekatan interpretabilitas model (misalnya *SHAP*) serta pemodelan spasial untuk mendukung perumusan kebijakan ketahanan pangan yang lebih presisi.

Kontribusi Penulis. **Mardatunnisa Isnaini:** Konseptualisasi, metodologi, perangkat lunak, validasi, analisis formal, investigasi, kurasi data, penulisan—persiapan draf asli, visualisasi. **Dela Gustiara:** Konseptualisasi, metodologi, perangkat lunak, validasi, analisis formal, investigasi, sumber daya, penulisan—persiapan draf asli, visualisasi. **Rizqi Annafi Muhadi:** Konseptualisasi, metodologi, perangkat lunak, validasi, analisis formal, investigasi, penulisan—persiapan draf asli. **Shalsabila Shafa:** Konseptualisasi, metodologi, perangkat lunak, validasi, analisis formal, investigasi, penulisan—persiapan draf asli. **Bagus Sartono:** penulisan—tinjauan dan penyuntingan, supervisi. **Aulia Rizki Firdawanti:** penulisan—tinjauan dan penyuntingan, supervisi. **Budi Susetyo:** penulisan—tinjauan dan penyuntingan. **Gerry Alfa Dito:** penulisan—tinjauan dan penyuntingan.

Ucapan Terima Kasih. Para penulis mengucapkan terima kasih kepada semua pihak yang telah berkontribusi dalam penelitian ini dan dalam penyusunan manuskrip. Kami sangat menghargai editor dan reviewer atas masukan serta dukungannya dalam menyempurnakan karya ini.

Pembiayaan. Penelitian ini tidak menerima pendanaan eksternal.

Konflik Kepentingan. Para penulis menyatakan tidak ada konflik kepentingan yang terkait dengan artikel ini.

Ketersediaan Data. Tidak tersedia.

Referensi

- [1] FAO, IFAD, UNICEF, WFP, and WHO, *The State of Food Security and Nutrition in the World 2025*. 2025, doi: [10.4060/cd6008en](https://doi.org/10.4060/cd6008en).
- [2] H. Dharmawan, B. Sartono, A. Kurnia, A. F. Hadi, and E. Ramadhani, "A study of machine learning algorithms to measure the variable importance in class-imbalance data of food insecurity cases in Indonesia," *Communications in Mathematical Biology and Neuroscience*, pp. 1–25, 2022, doi: [10.28919/cmbn/7636](https://doi.org/10.28919/cmbn/7636).
- [3] M. Mengstie, "Developing the predictive model for the level of food insecurity status of households using ensemble machine learning techniques with XAI," pp. 1–15, 2024, doi: [10.21203/rs.3.rs-5561434/v1](https://doi.org/10.21203/rs.3.rs-5561434/v1).
- [4] Badan Pusat Statistik Provinsi Jawa Barat, "Persentase penduduk miskin Provinsi Jawa Barat September 2024 turun menjadi 7,08 persen," 2025. [Online]. Available: <https://jabar.bps.go.id>. [Accessed: Feb. 17, 2026].
- [5] T. Pujilestari and T. Haryanto, "Determinants of household food security in West Nusa Tenggara, Indonesia," *ECONOSAINS*, vol. 18, pp. 24–38, 2020, doi: [10.21009/econosains.0181.03](https://doi.org/10.21009/econosains.0181.03).
- [6] K. N. Khikmah, B. Sartono, B. Susetyo, and G. A. Dito, "Performance comparative study of machine learning classification algorithms for food insecurity experience by households in West Java," vol. 9, no. 1, pp. 128–137, 2024, doi: [10.15575/join.v9i1.1012](https://doi.org/10.15575/join.v9i1.1012).
- [7] R. Qasrawi *et al.*, "Machine learning approach for predicting the impact of food insecurity on nutrient consumption and malnutrition in children aged 6 months to 5 years," *Children*, vol. 11, Art. no. 810, Jul. 2024, doi: [10.3390/children11070810](https://doi.org/10.3390/children11070810).
- [8] Y. M. Indah *et al.*, "Comparison of random forest, XGBoost, and LightGBM methods for the human development index classification," *Jambura Journal of Mathematics*, vol. 7, no. 1, 2025, doi: [10.37905/jjom.v7i1.28290](https://doi.org/10.37905/jjom.v7i1.28290).
- [9] E. Indrisari, H. Febiansyah, and B. Adiwino, "A systematic literature review on the application of machine learning for predicting stunting prevalence in Indonesia (2020–2024)," *Jurnal Sisfokom*, vol. 14, no. 3, pp. 277–283, 2025, doi: [10.32736/sisfokom.v14i3.2366](https://doi.org/10.32736/sisfokom.v14i3.2366).
- [10] E. Yuliani, B. Sartono, H. Wijayanto, A. F. Hadi, and E. Ramadhani, "Study of features importance level identification of machine learning classification model in sub-populations for food insecurity," *AIP Conference Proceedings*, 2022, doi: [10.1063/5.0111784](https://doi.org/10.1063/5.0111784).
- [11] G. Ke *et al.*, "LightGBM: A highly efficient gradient boosting decision tree," in *Proc. 31st Int. Conf. Neural Information Processing Systems (NIPS)*, 2017, pp. 3149–3157.
- [12] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in *Proc. 22nd ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining*, 2016, pp. 785–794, doi: [10.1145/2939672.2939785](https://doi.org/10.1145/2939672.2939785).
- [13] R. Supergiants *et al.*, "Evolution," *Galaxies*, pp. 1–25, 2019, doi: [10.3390/galaxies7040092](https://doi.org/10.3390/galaxies7040092).
- [14] M. Syukron, R. Santoso, and T. Widihari, "Perbandingan metode SMOTE random forest dan SMOTE XGBoost untuk klasifikasi tingkat penyakit hepatitis C pada imbalance class data," *Jurnal Gaussian*, vol. 9, pp. 227–236, 2020, doi: [10.14710/j.gauss.v9i3.28915](https://doi.org/10.14710/j.gauss.v9i3.28915).
- [15] H. Sunata, F. J. Azrullah, and Y. Rianto, "Komparasi tujuh algoritma identifikasi fraud ATM," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 7, no. 3, pp. 441–450, 2020, doi: [10.35957/jatisi.v7i3.471](https://doi.org/10.35957/jatisi.v7i3.471).
- [16] E. Sutoyo and M. A. Fadlurrahman, "Penerapan SMOTE untuk mengatasi imbalance class dalam klasifikasi television advertisement performance rating menggunakan artificial neural network," vol. 6, no. 3, pp. 379–385, 2020, doi: [10.26418/jp.v6i3.42896](https://doi.org/10.26418/jp.v6i3.42896).
- [17] C. T. M. Sitanggang, T. Novianti, and S. Amar, "Analisis neural network dengan metode backpropagation dalam melakukan peramalan terhadap produksi daging sapi," in *Prosiding Seminar Nasional Waluyo Jatmiko*, 2023, pp. 81–90.
- [18] M. D. Irnanda, A. S. Pratama, F. A. Putra, and S. Sugiyanto, "Application of artificial neural network (MLP) for multivariate analysis of stunting causes in Indonesia," *Journal of Applied Informatics and Computing*, vol. 9, no. 4, pp. 1785–1792, 2025, doi: [10.30871/jaic.v9i4.10205](https://doi.org/10.30871/jaic.v9i4.10205).
- [19] L. Breiman, "Random forests," *Machine Learning*, pp. 5–32, 2001.
- [20] P. Li, "Robust LogitBoost and adaptive base class (ABC) LogitBoost," in *Proc. Uncertainty in Artificial Intelligence*, 2012, doi: [10.48550/arXiv.1203.3491](https://doi.org/10.48550/arXiv.1203.3491).
- [21] C. J. C. Burges, "From RankNet to LambdaRank to LambdaMART: An overview," *Microsoft Research Technical Report*, 2010.