

Analisis Perbandingan Kinerja Metode Ensemble Bagging dan Boosting pada Klasifikasi Bantuan Subsidi Listrik di Kabupaten/Kota Bogor

Nanda Putri Cintari¹, Kevin Alifviansyah², Dhiya Ulayya Tsabitah³, Bagus Sartono⁴, Aulia Rizki Firdawanti⁵

nandaputricintari@apps.ipb.ac.id¹, kevinlifviansyah@apps.ipb.ac.id²,

dhiya.tsabitah@apps.ipb.ac.id³, bagusco@gmail.com⁴, arfirdawanti@gmail.com⁵

^{1,2,3,4,5} Departmen Statistika dan Sains Data, IPB University

Informasi Artikel

Diterima : 10 Des 2024

Direvisi : 17 Des 2024

Disetujui : 30 Des 2024

Kata Kunci

Bagging, Boosting, Ensemble, Extra Trees, Subsidi Listrik.

Abstrak

Klasifikasi penerima subsidi listrik merupakan langkah penting untuk memastikan program bantuan sosial pemerintah tersalurkan secara tepat sasaran sehingga diperlukan metode analisis yang tepat. Penelitian ini membandingkan metode *ensemble Bagging* dan *Boosting* untuk klasifikasi rumah tangga penerima subsidi listrik di Kabupaten dan Kota Bogor menggunakan data Susenas 2023 sebanyak 2002 rumah tangga. Pada metode *bagging* menggunakan *Random Forest* dan *Extra Trees*, sedangkan *boosting* mencakup *CatBoost* dan *LightGBM*. Hasil penelitian menunjukkan bahwa metode *Extra Trees* dari *bagging* memberikan kinerja terbaik dengan akurasi 91%, $F1_{score}$ 95%, dan sensitivitas 97%. Faktor kepemilikan barang elektronik dan fasilitas modern, seperti kepemilikan AC, laptop, dan televisi merupakan variabel paling signifikan dalam memengaruhi klasifikasi penerima subsidi listrik. Dengan akurasi tinggi dan minim bias, model ini efektif mendukung kebijakan berbasis data untuk distribusi subsidi listrik. Penelitian ini diharapkan menjadi rekomendasi strategis bagi pemerintah untuk meningkatkan efektivitas program subsidi listrik agar lebih efisien, tepat sasaran, dan mendukung peningkatan kesejahteraan masyarakat.

Keywords

Bagging, Boosting, Electricity Subsidy, Ensemble, Extra Trees.

Abstract

The classification of electricity subsidy recipients is an crucial step to ensure that the government's social assistance program is distributed in a targeted manner, so an appropriate analysis method is needed. This research compares the Bagging and Boosting ensemble methods for the classification of households receiving electricity subsidies in Bogor Regency and City using Susenas 2023 data totaling 2002 households. The bagging method uses Random Forest and Extra Trees, while boosting includes CatBoost and LightGBM. The results showed that the Extra Trees method of bagging provided the best performance with 91% accuracy, 95% $F1_{score}$, and 97% sensitivity. Factors such as ownership of electronic goods and modern facilities, such as ownership of air conditioners, laptops, and televisions are the most significant variables in influencing the classification of electricity subsidy recipients. With high accuracy and minimal bias, this model effectively supports data-driven policies for electricity subsidy distribution. This research is expected to be a strategic recommendation for the government to improve the effectiveness of the electricity subsidy program to be more efficient, well-targeted, and support the improvement of people's welfare.

A. Pendahuluan

Klasifikasi merupakan teknik pembelajaran mesin yang bertujuan untuk mengkategorikan data ke dalam kelas-kelas yang telah ditentukan berdasarkan karakteristik yang dimilikinya [1]. Proses klasifikasi melibatkan pembangunan suatu model prediksi yang mampu memetakan data baru ke dalam kelas yang tepat berdasarkan pola yang telah diidentifikasi dari data pelatihan [2]. Model ini dibangun melalui pembelajaran terhadap sekumpulan data berlabel dengan setiap data telah diketahui kelasnya [3]. Klasifikasi memiliki permasalahan antara lain terbatas pada data kompleks, tidak stabil pada data yang bervariasi, dan menghasilkan akurasi rendah pada pemodelan dasar. Keterbatasan ini muncul karena data kompleks seringkali memiliki karakteristik seperti multikolinearitas, non-linearitas, dan dimensi tinggi. Selain itu, pemodelan klasifikasi sangat sensitif terhadap variasi data sehingga perubahan kecil dapat menghasilkan model yang berbeda secara signifikan [4]. Distribusi kelas tidak seimbang juga menjadi masalah umum sehingga model cenderung bias terhadap kelas mayoritas. Untuk mengatasi permasalahan tersebut, pendekatan *ensemble* dapat digunakan [5].

Ensemble merupakan metode penggabungan prediksi dari beberapa model dasar untuk menghasilkan prediksi yang lebih baik dan *robust* [6]. Menurut [7], aplikasi metode *ensemble* dalam klasifikasi dan prediksi yang ditangani dengan baik, secara umum dapat menghasilkan akurasi dan stabilitas yang lebih tinggi dari penggunaan satu algoritma. *Ensemble* juga dapat digunakan dalam menangani permasalahan umum dalam algoritma pembelajaran yang disebabkan oleh *local optimal* dengan nilai optimal dapat dicapai sebuah algoritma berada dalam rentang nilai tertentu yang telah dibatasi [8].

Dua teknik *ensemble* yang banyak diterapkan dalam analisis data dan pemodelan prediktif adalah *bagging* dan *boosting*. Konsep *ensemble* dengan *boosting* bekerja dengan cara melatih kelompok model secara sekuensial dan kemudian menggabungkan keseluruhan model tersebut untuk melakukan prediksi, model yang dihasilkan belajar dari kesalahan model sebelumnya [6]. Sedangkan konsep *ensemble* dengan *bagging* dilakukan dengan menggabungkan banyak nilai dugaan menjadi satu nilai dugaan. Dengan menggunakan sampel berupa *bootstrap* untuk menghasilkan sampel-sampel data secara acak yang akan digunakan sebagai proses latih untuk setiap pohon. Secara umum *bagging* akan melakukan mekanisme *majority vote* untuk digabungkan sebagai pengklasifikasi utama dari model akhir yang dihasilkan [6].

Teknik *ensemble* telah banyak digunakan dalam klasifikasi data untuk membantu pemerintah mengidentifikasi dan mengelompokkan masyarakat menjadi segmen-segmen yang lebih spesifik, sehingga program bantuan sosial dapat disalurkan secara tepat sasaran. Beberapa diantaranya penelitian oleh [9] yang membandingkan metode *Random Forest* dengan *Support Vector Machine* (SVM) dalam mengklasifikasikan penerima bantuan sosial BPNT berdasarkan 21 peubah bebas. Hasil penelitian menunjukkan metode *Random Forest* dan SVM memiliki ketelitian yang cukup baik dalam melakukan klasifikasi, yakni sebesar 71–72%. Pada tahun 2021, [11] membandingkan klasifikasi penerima Bantuan Langsung Tunai dengan menggunakan pendekatan *Decision Tree* dan *AdaBoost*. Hasil menunjukkan *AdaBoost* sebagai metode terbaik dengan akurasi hasil sebesar 85%. Penelitian juga dilakukan oleh [12] dengan melakukan perbandingan metode

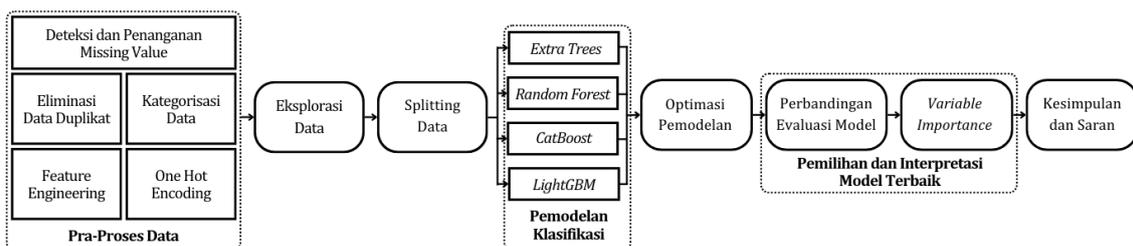
Adaptive Boost, CatBoost, Gradient Boost Machine, Light Gradient Boost Machine, dan Extreme Gradient dalam klasifikasi bantuan pemerintah. Hasil menunjukkan *CatBoost* sebagai metode terbaik dengan akurasi sebesar 91%.

Salah satu program bantuan sosial yang digalakkan pemerintah untuk meningkatkan kesejahteraan masyarakat adalah kebijakan subsidi listrik. Kebijakan ini bertujuan untuk memastikan akses yang adil dan terjangkau terhadap energi listrik bagi seluruh lapisan masyarakat, terutama bagi rumah tangga miskin. Melalui Peraturan Menteri ESDM Nomor 29 Tahun 2016, pemerintah telah mengatur mekanisme penyaluran subsidi listrik secara tepat sasaran, dengan mempertimbangkan tingkat konsumsi energi listrik setiap rumah tangga. Berdasarkan Peraturan Menteri ESDM RI Nomor 3 Tahun 2024 menunjukkan bahwa bentuk subsidi terhadap tarif tenaga listrik dibagi kedalam dua jenis dengan daya listrik sebesar 450 VA dan 900 VA. Agar program subsidi dapat berjalan efektif dan efisien, diperlukan analisis data yang komprehensif untuk mengidentifikasi karakteristik rumah tangga yang berhak menerima subsidi.

Penelitian ini bertujuan untuk meningkatkan akurasi dalam mengidentifikasi rumah tangga penerima subsidi listrik di Kabupaten dan Kota Bogor tahun 2023. Dengan membandingkan kinerja algoritma *bagging* (*Random Forest* dan *Extra Trees*) serta *boosting* (*CatBoost* dan *LightGBM*), penelitian berupaya menemukan model yang paling optimal untuk mendukung program penyaluran subsidi yang lebih tepat sasaran. Model terbaik akan dipilih berdasarkan tingkat akurasi dan keseimbangan hasil parameter dengan menggunakan $F1_{score}$ tertinggi, sehingga dapat memberikan rekomendasi bagi pengambilan keputusan terkait kebijakan subsidi listrik.

B. Metode Penelitian

Penelitian terdiri dari beberapa tahapan yang tertera pada Gambar 1. Tahap pra-pemrosesan data dilakukan secara komprehensif untuk memastikan kualitas dan integritas data sebelum analisis lebih lanjut. Proses ini meliputi penanganan data hilang, eliminasi data duplikat, kategorisasi ulang variabel kategorik untuk meningkatkan representasi data, membentuk peubah baru berdasarkan informasi yang tersedia serta transformasi peubah kategorik menjadi vektor numerik. Selanjutnya, eksplorasi data dilakukan dengan visualisasi menggunakan grafik guna mengidentifikasi pola, *outlier*, dan anomali yang mendasari distribusi data. Pemodelan klasifikasi dilakukan berdasarkan pembagian data dengan proporsi 70:30, serta optimasi *hyperparameter* untuk memperoleh model yang generalisasi dan mampu mengidentifikasi variabel yang paling berpengaruh terhadap klasifikasi penerima subsidi listrik.



Gambar 1. Tahapan Penelitian

1. Dataset

Penelitian ini menggunakan data mikro Susenas Kabupaten dan Kota Bogor tahun 2023 berjumlah 2002 rumah tangga. Berdasarkan Peraturan Menteri ESDM RI Nomor 3 Tahun 2024, bentuk subsidi terbagi menjadi dua yaitu daya listrik yaitu sebesar 450 VA dan 900 VA. Oleh karena itu, peubah respon pada penelitian ini dikategorikan menjadi 2 kelompok yaitu rumah tangga tidak memperoleh subsidi listrik (0) serta rumah tangga penerima subsidi listrik (1). Sementara itu, terdapat 15 peubah penjelas yang disajikan pada Tabel 1.

Tabel 1. Dataset Penelitian

Deskripsi	Kode	Peubah	Tipe Data	Faktor
Status Penerimaan Subsidi Listrik	Y	Dependen	Kategorik	
Penerimaan PKH	X1	Independen	Kategorik	Kondisi Sosial dan Ekonomi
Status Kemiskinan	X2	Independen	Kategorik	
Status Kepemilikan Bangunan	X3	Independen	Kategorik	
Jumlah Keluarga	X4	Independen	Numerik	
Luas Bangunan	X5	Independen	Kategorik	Fisik Bangunan Tempat Tinggal
Jenis Atap Terluas	X6	Independen	Kategorik	
Jenis Dinding Terluas	X7	Independen	Kategorik	
Jenis Lantai Terluas	X8	Independen	Kategorik	
Sumber Air Utama	X9	Independen	Kategorik	Utilitas dan Fasilitas Dasar
Jenis Bahan Bakar Memasak	X10	Independen	Kategorik	
Kepemilikan AC	X11	Independen	Kategorik	Kepemilikan Barang Elektronik dan Fasilitas Modern
Kepemilikan Kulkas	X12	Independen	Kategorik	
Kepemilikan Telepon Rumah	X13	Independen	Kategorik	
Kepemilikan Laptop/Komputer	X14	Independen	Kategorik	
Kepemilikan Televisi	X15	Independen	Kategorik	

Dalam upaya meningkatkan akurasi analisis, dilakukan proses *feature engineering* untuk membentuk tiga variabel baru, yaitu peubah status kemiskinan (X2), sumber air utama (X9), dan jenis bahan bakar memasak (X10). Peubah status kemiskinan diperoleh melalui kategorisasi pendapatan per kapita rumah tangga di wilayah Kabupaten dan Kota Bogor guna mengidentifikasi rumah tangga yang berada di bawah garis kemiskinan. Sementara itu, peubah sumber air utama dikategorikan berdasarkan tiga jenis sumber air yang umum digunakan, yaitu sumber air berbasis listrik, sumber air berbasis non-listrik, dan sumber air lainnya. Peubah jenis bahan bakar memasak dikategorikan berdasarkan dua jenis, yaitu jenis bahan bakar memasak berbasis listrik dan jenis bahan bakar memasak berbasis non-listrik.

2. Metode *Ensemble*

Ensemble learning merupakan metode *machine learning* yang menggabungkan beberapa model tunggal (*base model*) untuk menghasilkan model prediksi yang lebih baik. Prinsip dasar *ensemble learning* adalah menggabungkan beberapa model yang memiliki kinerja individu kurang optimal, sehingga memperoleh model yang lebih baik dalam generalisasi dan stabilitas [2]. Penggabungan tersebut menjadi keunggulan metode *ensemble* karena mampu meningkatkan akurasi prediksi dan lebih *robust* terhadap *noise*, sehingga dapat mengurangi risiko *overfitting* yang sering terjadi pada model tunggal. *Ensemble learning* terbagi menjadi 3 model yaitu *bagging*, *boosting* dan *stacking* [10].

3. *Bagging*

Bagging merupakan salah satu teknik dalam *ensemble* yang menggabungkan beberapa model dasar secara paralel untuk meningkatkan kinerja prediksi. Metode ini bekerja dengan cara mengambil sampel ulang (*bootstrap*) dari data pelatihan secara berulang, lalu melatih model dasar yang identik pada setiap sampel [5]. Prediksi akhir diperoleh dengan mengagregasi hasil prediksi dari semua model dasar, misalnya dengan mengambil rata-rata (untuk regresi) atau voting mayoritas (untuk klasifikasi).

a. *Extra Trees*

Extra Trees merupakan algoritma *ensemble* yang membangun model prediksi melalui serangkaian pohon keputusan (*Decision Tree*). Dalam proses pengambilan keputusan, algoritma ini menggunakan aturan *split* yang ditentukan berdasarkan pemilihan subset acak dari fitur dan titik acak parsial. Terdapat tiga parameter utama yang mempengaruhi kinerja *Extra Trees* yaitu jumlah pohon dalam *ensemble*, jumlah fitur yang dipilih secara acak, serta jumlah minimum sampel yang diperlukan untuk membagi simpul pada pohon keputusan. Dengan memanfaatkan mekanisme acak parsial, *Extra Trees* menawarkan fleksibilitas dalam pembuatan keputusan sehingga menghasilkan model yang lebih baik dan mampu menangani variasi data secara efektif. Selain itu, dengan menerapkan metode pengambilan ulang subset data atau *resampling*, tingkat akurasi model dapat ditingkatkan [8].

b. *Random Forest*

Random Forest merupakan metode pengembangan berbasis *ensemble* yang membangun sekumpulan pohon keputusan (*Decision Tree*) untuk membentuk sebuah hutan (*forest*). Setiap pohon dalam hutan dilatih secara independen dengan menggunakan teknik *bootstrap aggregating (bagging)* dan pemilihan fitur secara acak (*random feature selection*) yang bertujuan untuk menentukan fitur terbaik dan meningkatkan akurasi model klasifikasi [2]. Metode ini memiliki beberapa keunggulan, di antaranya memberikan akurasi yang lebih tinggi dan tingkat kesalahan (*error rate*) yang lebih rendah, tahan terhadap keberadaan *outlier*, mampu mengatasi masalah *overfitting* pada data latih dalam jumlah besar, serta efektif dalam menangani data yang mengandung nilai hilang [2].

4. *Boosting*

Boosting merupakan algoritma yang digunakan untuk mengurangi secara signifikan kesalahan pada berbagai macam "*weak*" *learning algorithm* untuk membentuk model *ensemble* yang kuat [4]. Pada setiap iterasi, model dasar dilatih dengan memberikan bobot yang lebih besar pada sampel data yang sulit diklasifikasi oleh model sebelumnya. Proses ini berulang hingga diperoleh sejumlah model dasar yang kemudian dikombinasikan secara tertimbang untuk menghasilkan prediksi akhir. *Boosting* akan menghasilkan akurasi yang baik apabila dalam pengulangan *classifier* yang terbentuk mendekati nilai akurasi 50%.

a. *CatBoost*

CatBoost (Categorical Boosting) adalah algoritma *Gradient Boosting* yang dirancang untuk menangani data kategorikal secara efisien dengan

menggunakan bilangan biner dari pohon keputusan (*Decision Tree*) sebagai dasar prediksi [6]. Algoritma ini mengintegrasikan *ordered boosting* untuk mencegah *target leakage* dan meminimalkan fungsi kerugian (*loss function*) secara iteratif, menghasilkan model yang efektif dengan performa tinggi. Keunggulan utamanya adalah kemampuannya mengolah variabel kategorikal tanpa memerlukan pra-pemrosesan ekstensif, seperti *label encoding* atau *one-hot encoding*. Parameter utama yang memengaruhi kinerja model meliputi jumlah iterasi, tingkat pembelajaran (*learning rate*), dan kedalaman pohon (*tree depth*), yang perlu dioptimalkan untuk mencapai akurasi terbaik.

b. *LightGBM*

LightGBM atau *Light Gradient Boosting Machine* merupakan algoritma *gradient boosting* yang bekerja dengan membangun sejumlah model *decision tree* secara bertahap. Dimana setiap model baru memperbaiki kesalahan model sebelumnya dengan penambahan fitur-fitur yang membantu untuk memperbaiki hasil. Dalam setiap tahap, *LightGBM* menggunakan teknik seperti bagian pemilihan pohon dan histogram untuk membuat proses pembelajaran lebih cepat dan mengurangi memori yang dibutuhkannya. Parameter utama dalam *LightGBM* meliputi jumlah iterasi (*num_iterations*), tingkat pembelajaran (*learning rate*), kedalaman maksimum pohon (*max_depth*), dan jumlah daun maksimum (*num_leaves*), yang secara langsung memengaruhi kompleksitas dan akurasi model.

5. Evaluasi Kinerja Klasifikasi

Kinerja model dapat diukur dengan membandingkan hasil prediksi dengan data aktual menggunakan *confusion matrix*. *Confusion matrix* adalah tabel yang digunakan untuk menilai performa model klasifikasi dengan membandingkan hasil prediksi model terhadap nilai aktual data yang diamati. Matriks ini terdiri dari empat komponen utama.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN}$$

$$\text{Sensitivitas} = \frac{TP}{TP+FN}$$

$$\text{Spesifisitas} = \frac{TN}{TN+FP}$$

$$F1_{score} = 2 \cdot \frac{\left(\frac{TP}{TP+FP}\right) \cdot \left(\frac{TP}{TP+FN}\right)}{\left(\frac{TP}{TP+FP}\right) + \left(\frac{TP}{TP+FN}\right)}$$

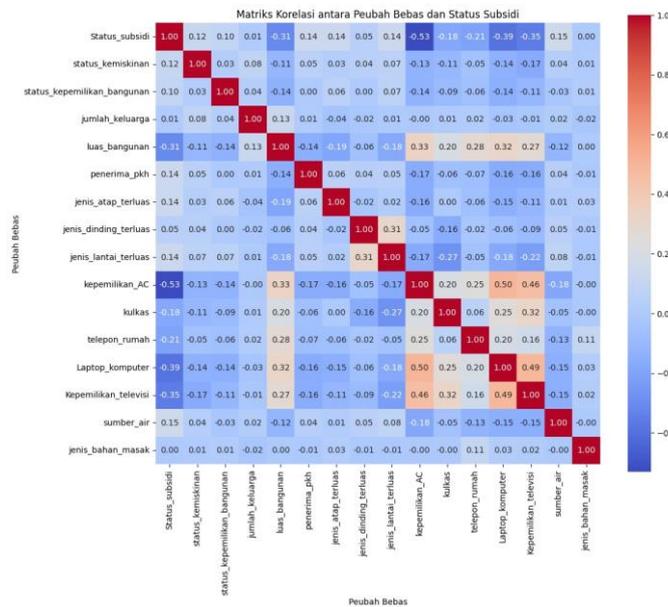
True Positive (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Untuk mengevaluasi kinerja model, beberapa metrik dapat dihitung dari matriks ini, seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Dalam penelitian ini, metrik *accuracy* dan *F1_{score}* dipilih sebagai metrik kinerja utama karena keduanya memberikan gambaran yang lebih komprehensif, *accuracy* menunjukkan persentase prediksi yang benar secara keseluruhan, sedangkan *F1_{score}* mencerminkan keseimbangan antara *precision* dan *recall*, yang sangat penting dalam konteks data dengan ketidakseimbangan kelas (*imbalanced data*).

C. Hasil dan Pembahasan

1. Pra-pemrosesan dan Eksplorasi Data

Pada tahap awal, data dilakukan pra-pemrosesan guna mengoptimalkan penggunaan data dalam analisis. Hasil pemeriksaan awal menunjukkan tidak adanya *missing value* pada data yang berpotensi menyebabkan penurunan efisiensi model dan *overfitting*, sehingga tidak dibutuhkan penanganan lebih lanjut. Namun, sebanyak 324 amatan terdeteksi sebagai data duplikat dan dengan jumlah tersebut, dibutuhkan adanya suatu penanganan untuk menghindari terjadinya kebiasaan dalam pemodelan. Salah satu cara untuk menanganin hal tersebut adalah dengan menghapus keberadaan duplikat dan menyisakan satu entri untuk setiap duplikat yang terdeteksi.

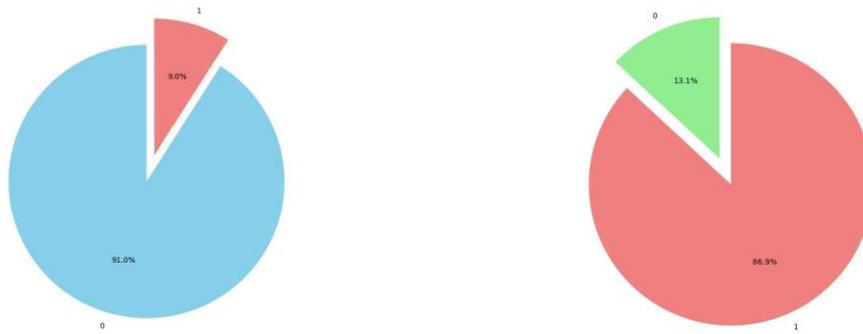
Dalam melakukan klasifikasi, penting untuk mencari keterkaitan hubungan antar variabel guna memahami interaksi antara variabel independen dan variabel dependen. Identifikasi hubungan yang signifikan pada kedua variabel tersebut dapat meningkatkan kemampuan model untuk memprediksi kelas dengan lebih akurat. Selain itu hubungan antar variabel independen juga dapat membantu mendeteksi keberadaan multikolinieritas yang dapat berpengaruh pada akurasi model klasifikasi. Gambar 2 merupakan hasil analisis korelasi antar variabel independen dan berdasarkan grafik terlihat bahwa tidak terdapat variabel yang memiliki hubungan berkorelasi tinggi dengan variabel independen lainnya.



Gambar 2. Matriks Korelasi

Ketidakmampuan sebagian kelompok masyarakat dalam memenuhi kebutuhan hidupnya menjadi dasar utama perlunya bantuan atau subsidi. Untuk memperoleh gambaran yang akurat mengenai kesenjangan sosial dan ekonomi, identifikasi jumlah penduduk miskin di suatu wilayah merupakan langkah yang krusial. Gambar 3(a) menyajikan perbandingan rumah tangga miskin Kabupaten dan Kota Bogor. Data mengindikasikan bahwa 9% dari total 1678 penduduk memiliki status sosial ekonomi di bawah garis kemiskinan. Namun, apabila dibandingkan dengan jumlah penerima bantuan subsidi listrik pada Gambar 3(b),

sebanyak 1459 rumah tangga atau 86,9% dari total rumah tangga di Kabupaten dan Kota Bogor menerima bantuan pemerintah, subsidi listrik.



(a) Proporsi Status Kemiskinan

(b) Proporsi Subsidi Listrik

Gambar 3. Eksplorasi Peubah

2. Pemodelan Awal dengan *Bagging* dan *Boosting*

Terdapat empat metode yang merepresentasikan masing-masing pendekatan *ensembl bagging* dan *boosting*. Adapun setiap metode dilakukan pemodelan awal terhadap pembagian data dengan proporsi 70:30. Pemodelan ini bertujuan untuk menguji sejauh mana model dapat menggeneralisasikan data baik pada proses pemodelan maupun pengujian.

Tabel 2. Evaluasi Kinerja Pemodelan Awal

Evaluasi	<i>Bagging</i>		<i>Boosting</i>	
	<i>Extra Trees</i>	<i>Random Forest</i>	<i>CatBoost</i>	<i>LightGBM</i>
Akurasi	0,87	0,88	0,87	0,89
$F1_{score}$	0,93	0,93	0,93	0,94
Sensitivitas	0,94	0,95	0,94	0,96
Spesifisitas	0,40	0,40	0,41	0,41

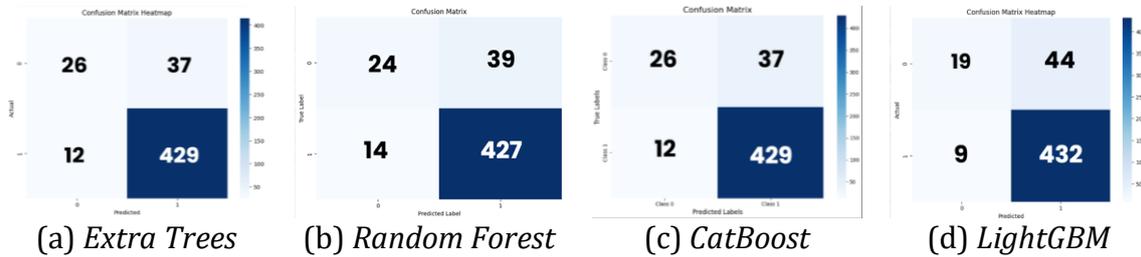
Tabel 2 menunjukkan hasil evaluasi kinerja pemodelan awal dengan *bagging* dan *boosting*. Terlihat bahwa secara keseluruhan model menghasilkan kinerja pemodelan yang sangat baik. Hal ini terlihat dari nilai metrik akurasi, $F1_{score}$ dan sensitivitas yang tinggi, melampaui ambang batas nilai 85%. Hasil eksplorasi data pada Gambar 3(b), mengindikasikan adanya ketidakseimbangan dalam data. Namun, berdasarkan hasil pemodelan awal pada Tabel 2, seiring dengan tingginya nilai akurasi yang diperoleh, hasil sensitivitas mampu mengimbangi dengan memperoleh nilai yang tinggi. Hal ini menunjukkan model mampu memprediksikan kelas minoritas dengan baik sehingga penanganan data tidak seimbang tidak perlu dilakukan.

3. Optimasi Pemodelan

Optimasi parameter model merupakan aspek yang krusial dalam pemodelan klasifikasi. Proses pemilihan *hyperparameter tuning* bertujuan untuk menemukan kombinasi parameter terbaik yang dapat memaksimalkan kinerja model. *Grid search* merupakan salah satu teknik yang umum digunakan. Dengan mengevaluasi secara sistematis semua kombinasi parameter yang mungkin dalam suatu ruang

parameter, *grid search* dapat mengidentifikasi kombinasi terbaik yang menghasilkan kinerja model paling optimal.

Pemodelan klasifikasi dengan menggunakan *hyperparameter tuning* dilakukan terhadap empat model klasifikasi, yaitu *Extra Trees*, *Random Forest*, *CatBoost*, dan *LightGBM*. Proses ini bertujuan untuk mendapatkan konfigurasi parameter optimal bagi setiap model. Berdasarkan hasil evaluasi model Gambar 4 menggunakan *confusion matrix*, keempat model menunjukkan tingkat prediksi benar yang tinggi untuk mengklasifikasikan rumah tangga penerima subsidi listrik.



Gambar 4. Confusion Matrix pada Data Test

Berdasarkan matriks konfusi pada Gambar 4, setiap model berhasil mengklasifikasikan lebih dari 400 rumah tangga sebagai penerima subsidi dengan benar. Selain itu, model juga mampu mengidentifikasi sekitar 20 rumah tangga yang tidak berhak menerima subsidi. Hasil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik, meskipun pada kelas minoritas.

Tabel 3. Perbandingan Evaluasi Kinerja

Perbandingan	Bagging		Boosting		
	Extra Trees	Random Forest	CatBoost	LightGBM	
Parameter	<i>minsplit</i> : 10 <i>maxdepth</i> : 20 <i>minleaf</i> : 4 <i>n estimator</i> : 100	<i>minsplit</i> : 5 <i>maxdepth</i> : 10 <i>n estimator</i> : 300	<i>depth</i> : 8 <i>iterations</i> : 1000 <i>learning rate</i> : 0,01 <i>leaf reg</i> : 100	<i>learning rate</i> : 0,01 <i>maxdepth</i> : 10 <i>num leave</i> : 50 <i>n estimator</i> : 300	
Train	Akurasi	0,90	0,93	0,92	0,91
	$F1_{score}$	0,95	0,96	0,92	0,95
	Sensitivitas	0,97	0,98	0,98	0,98
	Spesifisitas	0,51	0,61	0,56	0,49
Test	Akurasi	0,91	0,89	0,89	0,89
	$F1_{score}$	0,95	0,94	0,87	0,94
	Sensitivitas	0,97	0,97	0,97	0,97
	Spesifisitas	0,41	0,38	0,33	0,30

Tabel 3 menunjukkan perbandingan evaluasi kinerja model terhadap empat metode yang digunakan dalam penelitian serta parameter optimalnya. Semua metode baik pada data *train* maupun data *test* menghasilkan evaluasi kinerja yang baik. Perbandingan akurasi dan sensitivitas pada keempat metode menunjukkan hasil yang baik dan tidak berbeda jauh. Hal ini berarti model dapat memprediksi kelas minoritas dengan baik dan tidak terjadi indikasi adanya *overfitting* yang membutuhkan penanganan lebih lanjut.

Dalam upaya menentukan pemodelan terbaik, metrik utama yang digunakan adalah akurasi dan $F1_{score}$. Hal ini dikarenakan dalam masalah klasifikasi biner, kedua metrik ini sangat berguna untuk mengevaluasi kinerja model. Akurasi

memberikan gambaran umum tentang seberapa sering model memberikan prediksi yang benar, sementara $F1_{score}$ memberikan nilai rata-rata harmonik antara presisi dan *recall*, sehingga lebih sensitif terhadap ketidakseimbangan kelas.

Berdasarkan Tabel 3, metode *Extra Trees* memberikan evaluasi kinerja akurasi dan $F1_{Score}$ paling baik dibandingkan model lainnya. Diperoleh akurasi tertinggi sebesar 0,90 artinya model *Extra Trees* mampu mengklasifikasikan data dengan benar sebesar 90%. $F1_{score}$ model tertinggi sebesar 95% yang menunjukkan keseimbangan antara presisi dan sensitivitas. Nilai sensitivitas sebesar 0,97 berarti model *Extra Trees* dapat mengidentifikasi sekitar 97% dari keseluruhan data kelas positif dengan benar. Nilai akurasi dan $F1_{score}$ pada data *train* dan *test* memperoleh hasil yang sama menandakan model stabil.

4. Pemodelan Akhir

Setelah dilakukan pemodelan dengan *hyperparameter tuning*, metode *Extra Trees* memberikan evaluasi kinerja akurasi dan $F1_{score}$ paling baik dibandingkan model lainnya. Langkah selanjutnya, melakukan pemodelan *Extra Trees* pada keseluruhan data dengan parameter *minspl* 10, *maxdepth* 20, *minleaf* 4, dan *n_estimator* 100. Evaluasi kinerja model tersebut dengan *confusion matrix* ditunjukkan pada Gambar 5.



Gambar 5. *Confusion Matrix* Model *Extra Trees* pada Keseluruhan Data

Berdasarkan *confusion matrix* tersebut, terdapat 1417 rumah tangga penerima subsidi berhasil diprediksi secara benar. Sementara itu, hanya 99 rumah tangga bukan penerima subsidi berhasil diprediksi secara benar. Selain *confusion matrix*, evaluasi kinerja klasifikasi dapat diukur dengan beberapa metrik yaitu akurasi, $F1_{score}$, spesifisitas, dan sensitivitas.

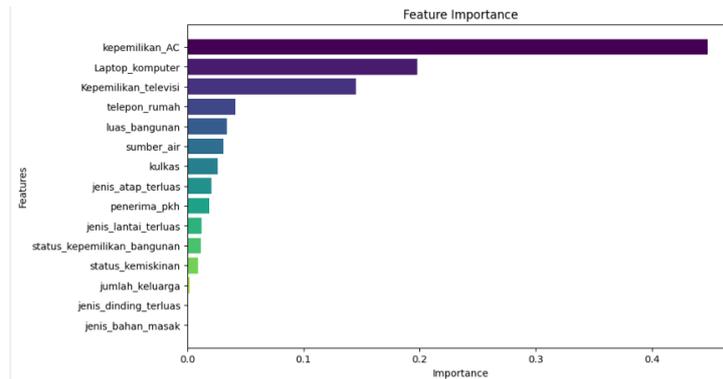
Tabel 4. Evaluasi Kinerja Model *Extra Trees* pada Keseluruhan Data

Akurasi	$F1_{score}$	Sensitivitas	Spesifisitas
0,90	0,95	0,97	0,45

Pemodelan *Extra Trees* pada keseluruhan data diperoleh akurasi sebesar 0,90 berarti model *Extra Trees* mampu mengklasifikasikan penerima subsidi dan bukan penerima subsidi dengan benar sebesar 90%. $F1_{score}$ diperoleh sebesar 95% yang menunjukkan keseimbangan antara presisi dan sensitivitas sehingga model mengidentifikasi penerima subsidi dengan benar tanpa terlalu banyak kesalahan.

Nilai sensitivitas sebesar 0,97 berarti model *Extra Trees* dapat mengidentifikasi sekitar 97% penerima subsidi dengan benar.

5. Feature Importance



Gambar 6. Feature Importance Model *Extra Trees* pada Keseluruhan Data

Gambar 6 menunjukkan *feature importance* pemodelan *Extra Trees* bahwa kepemilikan AC merupakan faktor paling signifikan dalam menentukan prediksi model dengan nilai 0.448. Hal ini diikuti oleh fitur kepemilikan laptop/komputer dan kepemilikan televisi, yang secara keseluruhan mencerminkan kepemilikan barang elektronik dan fasilitas modern. Sementara itu, jenis bahan bakar memasak, jenis dinding terluas dan jumlah keluarga memiliki nilai paling rendah yang menunjukkan bahwa peubah ini tidak relevan dalam memengaruhi prediksi model. Secara keseluruhan, model ini sangat dipengaruhi oleh peubah-peubah yang mencerminkan kepemilikan barang elektronik dan fasilitas modern dibandingkan peubah yang mencerminkan kondisi sosial dan ekonomi serta peubah lainnya memiliki dampak yang lebih kecil.

D. Simpulan

Hasil analisis perbandingan kinerja metode *ensemble bagging* dan *boosting* dalam klasifikasi penerima subsidi listrik di Kabupaten dan Kota Bogor menunjukkan metode *Extra Trees* dari teknik *bagging* memberikan kinerja terbaik. Dengan metrik akurasi mencapai 91% dan $F1_{score}$ sebesar 95%, pendekatan ini berhasil mengidentifikasi penerima subsidi secara akurat serta efektivitas model dalam menangani data yang kompleks dan tidak seimbang. Dalam hal ini, rumah tangga dengan kepemilikan barang elektronik dan fasilitas modern menjadi faktor yang paling signifikan dalam menentukan klasifikasi penerima subsidi listrik. Oleh karena itu, diharapkan penelitian ini dapat memberikan rekomendasi bagi pemerintah serta pengambilan keputusan terkait kebijakan subsidi listrik, sehingga program bantuan sosial dapat disalurkan lebih tepat sasaran dan efisien kepada pihak yang membutuhkan.

E. Referensi

- [1] P.B.N. Setio, D.R.S. Saputro, & B. Winarno, "Klasifikasi dengan Pohon Keputusan Berbasis Algoritme C4.5" *In prisma Prosiding Seminar Nasional Matematika*, vol. 3, pp. 64-71, 2020.
- [2] A. Nugroho, I. Asror, & Y.F.A Wibowo, "Klasifikasi Tingkat Kualitas Udara DKI Jakarta Berdasarkan Open Government Data Menggunakan Algoritma Random Forest" *In e-Proceedings of Engineering*, vol. 10(2), pp. 1824-1843, 2023.
- [3] A. Andika, S. Syarli, & C.R. Sari, "Data Mining Klasifikasi Kelulusan Mahasiswa Menggunakan Metode Naïve Bayes," *Journal Pegguruang*, vol. 4(1), pp. 423-428. 2022.
- [4] X. Zhang, T. Zhao, H. Xu, W. Liu, J. Wang, X. Chen, & L. Liu, "GLC_FCS30D: the first global 30 m land-cover dynamics monitoring product with a fine classification system for the period from 1985 to 2022 generated using dense-time-series Landsat imagery and the continuous change-detection method," *Earth System Science Data*, vol. 16(3), pp. 1353-1381. 2024.
- [5] D.W. Triscowati, B. Sartono, A. Kurnia, D. Dirgahayu, & A.W. Wijayanto, "Classification of rice-plant growth phase using supervised random forest method based on landsat-8 multitemporal data," *International Journal of Remote Sensing and Earth Sciences (IJReSES)*, vol. 16(2), pp. 187-196. 2020.
- [6] Y.X. He, Y.C. Wu, C. Qian, & Z.H. Zhou, "Margin distribution and structural diversity guided ensemble pruning," *Machine Learning*, vol. 113(6), pp. 3545-3567. 2024.
- [7] Y. Liu, T. Yang, L. Tian, B. Huang, J. Yang, & Z. Zeng, "Ada-XG-CatBoost: A Combined Forecasting Model for Gross Ecosystem Product (GEP) Prediction," *Sustainability*, vol. 16(16), pp. 1-19. 2024.
- [8] A. S. Demir, T. F. Kurnaz, A.H. Kökçam, C. Erden, & U. Dağdeviren, "A comparative analysis of ensemble learning algorithms with hyperparameter optimization for soil liquefaction prediction," *Environmental Earth Sciences*, vol. 83(289). 2024.
- [9] A. Aldiyansyah, A.I. Purnamasari, & I. Ali, "Perbandingan Tingkat Akurasi Algoritma Decision Tree dan Random Forest dalam Mengklasifikasi Penerima Bantuan Sosial BPNT di Desa Silangit," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8(1), pp. 127-132. 2024.
- [10] M.H.D.M. Ribeiro, & L.D.S Coelho, (2020). Ensemble approach based on bagging, boosting and stacking for short-term prediction in agribusiness time series. *Applied soft computing*, vol. 86. 2020
- [11] L. Qadrini, A. Seppewali, A. Aina, "Decision Tree dan Adaboost pada Klasifikasi Penerima Program Bantuan Sosial," *Jurnal Inovasi Penelitian*, vol. 2(7), pp. 1959-19661. 2021.
- [12] E.L.V. Salvador, "Use of Boosting Algorithms in Household-Level Poverty Measurement: A Machine Learning Approach to Predict and Classify Household Wealth Quintiles in the Philippines," *arXiv preprint*. 2024.