

ANALISIS KLASIFIKASI KUALITAS HIDUP MANUSIA ANTAR KABUPATEN/KOTA DI INDONESIA MENGGUNAKAN ALGORITMA CATBOOST CLASSIFIER DAN SHAP VALUES

Karine Yoshefa Marybphoto Sitinjak

Program Studi Sains Aktuaria, Fakultas Sains, Institut Teknologi Sumatera, Lampung, Indonesia
karinyoshefaa@gmail.com

Ayu Sofia*

Program Studi Sains Aktuaria, Fakultas Sains, Institut Teknologi Sumatera, Lampung, Indonesia
Ayu.sofia@at.itera.ac.id

Linda Rasiyanti

Program Studi Sains Data, Fakultas Sains, Institut Teknologi Sumatera, Lampung, Indonesia
linda.rasiyanti@sd.itera.ac.id

Abstrak

Pembangunan manusia harus disertai dengan peningkatan kualitas hidup manusia yang dapat dilihat berdasarkan IPM dan faktor-faktor yang mempengaruhinya. Klasifikasi kualitas hidup manusia berdasarkan IPM ke dalam wilayah maju, berkembang, dan tertinggal memberikan gambaran kinerja pembangunan manusia di setiap wilayah kabupaten/kota di Indonesia. Algoritma *CatBoost Classifier* dan nilai *Shapley Additive Explanations* (SHAP) dapat digunakan untuk menghasilkan model klasifikasi yang akurat sekaligus menginterpretasikan pengaruh setiap variabel. Penelitian ini bertujuan untuk menganalisis klasifikasi kualitas hidup manusia antar kabupaten/kota di Indonesia berdasarkan IPM dan faktor-faktor yang mempengaruhinya. Model klasifikasi menggunakan algoritma *CatBoost Classifier* menghasilkan akurasi sebesar 92,23%. Kinerja terbaik terdapat pada kelas berkembang, sementara kelas tertinggal menunjukkan akurasi rendah akibat ketidakseimbangan data. Analisis nilai SHAP menunjukkan bahwa variabel paling berpengaruh pada kelas maju dan berkembang adalah rata-rata lama sekolah, pengeluaran per kapita, dan jenis wilayah. Pada kelas tertinggal, faktor pulau dan akses sanitasi menjadi penentu utama. Hasil ini menunjukkan bahwa pendidikan, kesejahteraan ekonomi, dan infrastruktur dasar sangat berperan dalam kualitas hidup manusia. Penelitian ini juga relevan dalam konteks risiko sosial aktuaria, khususnya untuk mendukung perencanaan jaminan sosial yang berbasis data dan wilayah.

Kata Kunci: analisis klasifikasi, *CatBoost Classifier*, SHAP Values, kualitas hidup manusia, risiko sosial

Abstract

Human development must go hand in hand with improving quality of life, as reflected by HDI and its influencing factors. Classifying quality of life based on HDI into developed, developing, and underdeveloped areas offers insights into the human development performance of each district/city in Indonesia. The *CatBoost Classifier* and SHAP values help build an accurate model while interpreting variable influences. This study analyzes human quality of life classification across districts/cities based on HDI and related factors. The *CatBoost* model achieved 92.23% accuracy, with the best performance in the developing class, while the underdeveloped class showed low accuracy due to data imbalance. SHAP analysis revealed that average years of schooling, per capita expenditure, and region type were key variables in the developed and developing classes, while island location and sanitation access dominated in the underdeveloped class. These findings highlight the importance of education, economic welfare, and basic infrastructure in shaping quality of life. This research also supports actuarial social risk planning, particularly in designing data- and region-based social security systems.

Keywords: classification analysis, *CatBoost Classifier*, SHAP Values, quality of human life, social risk

PENDAHULUAN

Negara Indonesia akan mengalami usia emas pada tahun 2045, yang mana pada saat tahun

tersebut Indonesia akan genap berusia 100 tahun atau satu abad. Pemerintah Indonesia menargetkan tahun tersebut menjadi momentum bersejarah yang akan mewujudkan mimpi Indonesia menjadi negara

maju dan sejajar dengan negara adidaya dengan memperoleh bonus demografis yang menjadi *the window of opportunity* sebagai negara maju (Sutikno, 2020). Presiden Republik Indonesia ke-7, Joko Widodo, menanggapi fenomena bonus demografis dengan menetapkan visi 4 pilar Indonesia Emas 2045 yaitu; pembangunan sumber daya manusia serta penguasaan ilmu pengetahuan dan teknologi; pembangunan ekonomi berkelanjutan; pemerataan pembangunan; pemantapan ketahanan nasional dan tata kelola pemerintahan (Puspa, 2023)..

Melalui visi tersebut terlihat bahwa sumber daya manusia yang unggul dan berkualitas memiliki urgensi sangat penting dalam mendorong perwujudan negara maju di masa yang akan datang. Dengan kata lain, pembangunan suatu negara dapat dipastikan akan meningkat pesat jika pemerintah berhasil membangun sumber daya manusia (Novrizaldi, 2022). Namun, pembangunan tersebut tidak akan bermakna apabila tidak disertai dengan kemampuan untuk meningkatkan kualitas hidup manusia yang direpresentasikan dalam bentuk parameter berupa Indeks Pembangunan Manusia (IPM) yang mengukur atau meninjau kinerja pembangunan manusia antar wilayah atau negara (WHO, 2022).

Beberapa masalah yang saat ini banyak terjadi di setiap wilayah Indonesia dan sangat berdampak bagi pembangunan berkelanjutan adalah diantaranya sebaran kemiskinan yang terkonsentrasi di wilayah perdesaan dan Indonesia Timur; ketimpangan pengeluaran per kapita dan rendahnya kepemilikan jaminan sosial (BPS, 2024) ; ketimpangan distribusi fasilitas kesehatan, sanitasi, serta cakupan jaminan kesehatan yang memperlemah ketahanan sistem kesehatan, terutama di wilayah timur Indonesia dan 3T (tertinggal, terdepan, terluar) (BPS, 2024). Selain itu, rata-rata lama sekolah yang stagnan dan rendahnya tingkat literasi masyarakat menjadi hambatan dalam pengembangan modal manusia yang produktif (UNESCO, 2022). Masih adanya rumah tangga tanpa akses air minum layak dan sanitasi sehat juga menunjukkan tantangan mendasar dalam pemenuhan kebutuhan dasar yang berdampak pada kesehatan masyarakat (UNICEF, 2022) serta pengangguran terbuka dan rendahnya partisipasi angkatan kerja di beberapa wilayah menunjukkan belum optimalnya pemanfaatan bonus demografi,

serta potensi risiko ketergantungan sosial (ILO, 2020). Di sisi lain, ketimpangan kualitas hidup ini juga berpotensi menjadi sumber tekanan fiskal dan pembiayaan jangka panjang terhadap program perlindungan sosial nasional, seperti Jaminan Kesehatan Nasional (JKN), bantuan sosial, dan subsidi wilayah (Nayottama, 2023). Oleh karena itu, penting untuk memetakan dan mengklasifikasikan wilayah tidak hanya berdasarkan capaian IPM saat ini, tetapi juga dengan mempertimbangkan profil risiko sosial dan potensi kebutuhan pembiayaan jangka panjang.

Berdasarkan masalah tersebut, penelitian ini bertujuan untuk mengklasifikasikan kabupaten/kota di Indonesia ke dalam kategori wilayah maju, berkembang, dan tertinggal berbasis kualitas hidup manusia (IPM). Penelitian ini menggunakan pendekatan *machine learning* dengan algoritma *CatBoost Classifier*, yang dirancang untuk menangani data kategorikal dan numerikal dengan lebih efisien (Hancock, 2020) dan mampu menangani data multivariat dengan akurasi tinggi dan minim *preprocessing*. Agar hasil model dapat diinterpretasikan secara transparan, digunakan pula teknik SHAP (*SHapley Additive exPlanations*) untuk menilai dan menunjukkan kontribusi masing-masing variabel yang berpengaruh terhadap kualitas hidup manusia dalam membedakan wilayah. Sebelumnya, Pahlevi, dkk (2024) mengklasifikasikan risiko *stunting* pada balita dengan menggunakan algoritma *CatBoost Classifier*, diperoleh hasil bahwa penelitian ini berhasil mengembangkan model klasifikasi risiko *stunting* pada balita yang secara iteratif memperbaiki prediksi model melalui pembaruan bertahap, sehingga secara keseluruhan meningkatkan akurasi klasifikasi. Selanjutnya T. Syamkalla, dkk (2024) menggunakan algoritma *CatBoost* dan SHAP dalam memprediksi popularitas *game indie* pada platform *steam*, diperoleh hasil bahwa model mampu secara efektif memisahkan dua kelas dengan menandakan performa yang baik dalam memprediksi popularitas *game indie*. Selain itu, analisis variabel *Shapley* mampu menyoroti beberapa faktor yang memiliki pengaruh signifikan terhadap popularitas *game indie*.

Berdasarkan penelitian sebelumnya, algoritma *CatBoost* yang digunakan sama-sama menunjukkan kemampuan pengembangan terhadap model yang lebih akurat dan efektif baik dalam melakukan

klasifikasi maupun memprediksi model. Namun, cukup penting untuk diketahui bahwa terdapat satu teknik untuk membantu mengoptimalkan kinerja dan performa model yaitu *hyperparameter tuning*. Setiap algoritma memiliki parameter yang harus disesuaikan pada dataset tertentu agar kinerja algoritma dapat bekerja lebih maksimal dalam menghasilkan model yang sangat baik dalam akurasi, efisiensi, dan penanganan masalah *overfitting* atau *underfitting*. Penggunaan teknik tersebut belum dieksplor lebih dalam oleh penelitian sebelumnya sehingga penulis tertarik untuk meneliti dan mengeksplor penggunaan teknik *hyperparameter tuning* dalam melakukan klasifikasi kualitas hidup manusia dari setiap kabupaten/kota di Indonesia menggunakan algoritma *CatBoost Classifier* dan analisis nilai *Shapley* atau SHAP.

Ilmu aktuaria relevan untuk diintegrasikan dalam penelitian ini, khususnya dalam estimasi keberlanjutan program sosial berdasarkan profil risiko sosial melalui klasifikasi kualitas hidup manusia. Dengan memanfaatkan hasil klasifikasi dan kontribusi variabel, dapat dilakukan proyeksi nilai kini (*present value*) dari potensi kebutuhan pembiayaan program perlindungan sosial di wilayah-wilayah dengan risiko sosial tinggi (Nayyotama, 2023). Pendekatan ini mendukung perencanaan berbasis risiko (*risk-based policy*) yang lebih efisien, tepat sasaran, dan berkelanjutan. Dengan demikian, penelitian ini berkontribusi dalam dua aspek penting. Pertama, menyediakan peta klasifikasi wilayah berbasis kualitas hidup dan profil risiko sosial yang dapat digunakan oleh pemerintah pusat dan wilayah dalam penentuan prioritas pembangunan. Kedua, menyediakan dasar untuk perhitungan kebutuhan pembiayaan perlindungan sosial berbasis aktuaria guna mendukung keberlanjutan program-program nasional. Keseluruhan hasil ini diharapkan memperkuat upaya percepatan pencapaian negara Indonesia yang maju, mengurangi ketimpangan wilayah, dan meningkatkan efektivitas kebijakan pembangunan manusia di Indonesia.

KAJIAN TEORI

KUALITAS HIDUP MANUSIA

Kualitas hidup manusia merupakan konsep yang mencakup berbagai aspek yang mempengaruhi kesejahteraan individu dan masyarakat. Secara umum, kualitas hidup dapat didefinisikan sebagai persepsi individu terhadap posisi mereka dalam kehidupan, yang dipengaruhi oleh berbagai faktor seperti kesehatan, pendidikan, lingkungan, ekonomi, dan hubungan sosial. Kualitas hidup tidak hanya mencakup aspek material, tetapi juga aspek psikologis dan sosial (Jacob, 2018). Menurut *World Health Organization* (WHO), kualitas hidup didefinisikan sebagai persepsi individu tentang posisi mereka dalam konteks budaya dan sistem nilai dimana mereka hidup, serta dalam hubungan dengan tujuan, harapan, standar, dan kekhawatiran mereka.

Selain itu, Diener dan rekan-rekannya (1999) mendefinisikan kualitas hidup sebagai kesejahteraan subjektif yang mencakup evaluasi individu terhadap kehidupan mereka secara keseluruhan, serta pengalaman emosional positif dan negatif. Hal ini menunjukkan bahwa kualitas hidup tidak hanya diukur dari faktor objektif, tetapi juga dari pengalaman subjektif individu. Kualitas hidup manusia direpresentasikan dalam bentuk parameter berupa Indeks Pembangunan Manusia (IPM) yang mengukur atau meninjau kinerja pembangunan manusia antar wilayah atau negara (WHO 2022).

Menurut Badan Pusat Statistik Indonesia (2016), Indeks Pembangunan Manusia dibangun melalui pendekatan tiga dimensi dasar. Dimensi tersebut mencakup umur panjang dan hidup sehat, pengetahuan dan standar hidup layak. Dalam mengukur dimensi kesehatan digunakan angka harapan hidup, selanjutnya untuk mengukur dimensi pendidikan digunakan indikator angka harapan lama sekolah.

Adapun untuk mengukur dimensi hidup layak digunakan indikator kemampuan daya beli masyarakat terhadap sejumlah kebutuhan pokok yang dilihat dari rata-rata besarnya Produk Nasional Bruto (PNB) per kapita (Pamungkas, 2022).. Nilai IPM berkisar antara 0-100. Apabila nilai IPM semakin dekat dengan 100, semakin bagus pembangunan manusia di wilayah tersebut. Rumus

umum yang digunakan untuk menghitung Indeks Pembangunan Manusia (IPM) menurut UNDP (2004) adalah sebagai berikut.

$$IPM = \frac{1}{3}(Y_1 + Y_2 + Y_3) \quad (2.1)$$

Dengan :

IPM : Indeks Pembangunan Manusia

Y_1 : Indeks Kesehatan

Y_2 : Indeks Pendidikan

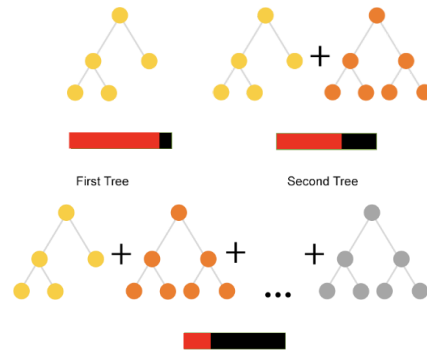
Y_3 : Indeks Standar Hidup Layak

BPS mengelompokkan IPM menjadi empat kelompok untuk mengorganisasikan wilayah-wilayah menjadi kelompok yang sama dalam hal pembangunan manusia. Dengan pembagian kelompok nilai IPM adalah sebagai berikut (Santoso, 2024).

1. Kelompok sangat tinggi : $IPM \geq 80$
2. Kelompok tinggi : $70 \leq IPM < 80$
3. Kelompok sedang : $60 \leq IPM < 70$
4. Kelompok rendah : $IPM < 60$

CATEGORICAL BOOSTING (CATBOOST) CLASSIFIER

Categorical Boosting (CatBoost) Classifier merupakan salah satu algoritma *machine learning* berbasis *boosting* yang dikembangkan untuk menangani masalah klasifikasi dan regresi. *CatBoost* dirancang untuk menangani data kategorikal dan numerikal dengan lebih efisien tanpa memerlukan pra-pemrosesan yang ekstensif seperti *one-hot encoding* (Hadiana, 2023). *CatBoost* merupakan implementasi dari *Gradient Boosting on Decision Tree* (GBDT) yang memiliki kombinasi *gradient boosting* dan pohon keputusan menggunakan model ansambel secara berulang. GBDT pada *CatBoost* membutuhkan pohon keputusan yang sesuai secara iteratif. Pohon keputusan klasifikasi yang digunakan akan mempelajari dengan cara; mengharuskan menghitung semua kemungkinan pemisahan variabel dari semua variabel dalam data, kemudian memilih variabel yang meningkatkan fungsi kerugian dengan nilai terbesar. Ilustrasi mengenai pohon keputusan iteratif oleh *CatBoost* dapat dilihat pada Gambar 1 berikut.



Gambar 1. Iterasi Pohon Pertama, Kedua, dan ke-N pada *CatBoost* [42]

MODEL KLASIFIKASI

CatBoost memiliki model klasifikasi berbasis *Gradient Boosting on Decision Trees* (GBDT) yang dirancang untuk bekerja secara efisien dengan variabel kategorikal dan memberikan kinerja optimal. *CatBoost* mampu bekerja untuk klasifikasi multikelas karena kemampuannya dalam menangani dataset dengan berbagai jenis variabel, termasuk variabel numerik dan kategorikal. Dalam klasifikasi multikelas, *CatBoost* dapat memprediksi probabilitas kelas menggunakan pendekatan berbasis *log-loss* atau *cross-entropy loss* yang sering digunakan untuk klasifikasi biner dan dinyatakan sebagai berikut (Syamkalla, 2024).

$$L(y, \hat{y}) = -(y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})) \quad (2.4)$$

Dimana y merupakan label aktual (0, 1, 2, ...) dan \hat{y} merupakan prediksi probabilitas dari model untuk kelas 1.

Model *CatBoost* bekerja dengan membangun pohon keputusan secara bertahap berdasarkan gradien dari fungsi kerugian (*loss*) untuk memperbaiki kesalahan prediksi dari model sebelumnya. Secara matematis, prediksi akhir model dinyatakan sebagai berikut (Pahlevi, 2024).

$$\hat{y}_i^{(t+1)} = \hat{y}_i^{(t)} + \eta \cdot h_t(x_i) \quad (2.5)$$

Dimana,

$\hat{y}_i^{(t+1)}$: prediksi yang diperbarui untuk contoh ke- i pada iterasi $t + 1$.

η : *learning rate* yang mengontrol seberapa banyak model harus mengoreksi prediksinya pada setiap iterasi.

$h_t(x_i)$: pohon keputusan yang dibangun pada iterasi ke- t , yang memprediksi sisa kesalahan dari model sebelumnya.

HYPERPARAMETER TUNING

Model *tuning* merupakan proses dalam memperkirakan parameter yang dapat meningkatkan kinerja model atau disebut juga dengan *hyperparameter tuning*. *Hyperparameter* adalah parameter yang ditetapkan sebelum proses pelatihan model dan tidak diperbarui selama *training*. *Hyperparameter* digunakan dengan menguji sekelompok *hyperparameter* pada parameter yang digunakan sebelumnya dengan tujuan untuk menghindari risiko *overfitting* atau *underfitting* (Prokhorenkova,2017). Terdapat beberapa metode umum yang digunakan untuk melakukan *hyperparameter tuning* diantaranya adalah *Grid Search*, *Randomized Search*, dan *Bayesian Optimization*. Metode *Randomized Search* merupakan metode yang memilih kombinasi *hyperparameter* secara acak dalam rentang yang telah ditentukan (Prokhorenkova,2017). Adapun *hyperparameter* yang digunakan mengikuti rentang nilai *default* dalam algoritma *CatBoost* berdasarkan situs *catboost.ai* yang dapat dilihat pada Tabel 1 berikut.

Tabel 1 *Hyperparameter Tuning* dalam *CatBoost* [42]

Hyperparameter	Rentang Nilai
<i>iterations</i>	[100, 200, 300, 500]
<i>learning_rate</i>	[0,01; 0,03; 0,05; 0,1]
<i>depth</i>	[3, 4, 5, 6]
<i>l2_leaf_reg</i> (L2 regularization coefficient on leaf values)	[3, 5, 7]
<i>class_weights</i> atau <i>auto_class_weights</i>	[1, 2, 5, 10] atau "Balanced" atau "SqrtBalanced"
<i>early_stopping_rounds</i>	[20 - 200]

EVALUASI KINERJA MODEL

Confusion matrix merupakan matriks evaluasi yang merangkum kinerja hubungan dari klasifikasi antara

model dengan beberapa pengujian data (Syamkalla, 2024)..

Tabel 2 *Confusion Matrix*

Aktual	Prediksi	
	Positif	Negatif
Positif	TP	FN
Negatif	FP	TN

Tabel 2 memperlihatkan empat parameter yang digunakan untuk mengevaluasi kinerja model klasifikasi yaitu TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), dan FN (*False Negative*). Ukuran berdasarkan *confusion matrix* mencakup akurasi, *recall*, presisi, *F1-Score*, *Area Under Curve (AUC)*, dan *Receiver Operating Characteristic (ROC)* yang digunakan untuk mengidentifikasi model-model yang baik dalam mengklasifikasikan suatu set data tertentu

- a) Akurasi
Akurasi adalah kemampuan model untuk mengklasifikasikan data dengan akurat dan dapat diandalkan.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \tag{2.7}$$

- b) *Recall*
Recall atau *sensitivity* menunjukkan kemampuan model untuk menemukan seluruh data yang benar-benar termasuk dalam suatu kelas. Dengan kata lain, *recall* mengukur berapa banyak dari total kasus sebenarnya suatu kelas yang berhasil ditemukan oleh model.

$$Recall = \frac{TP}{TP+FN} \tag{2.8}$$

- c) Presisi
Presisi mengukur seberapa tepat model dalam memberikan prediksi positif terhadap suatu kelas tertentu. Ini menunjukkan berapa banyak prediksi yang benar dari semua yang diprediksi sebagai kelas tersebut.

$$Presisi = \frac{TP}{TP+FP} \tag{2.9}$$

- d) *F1-Score*

F1-Score memperhitungkan presisi dan *recall* dari model klasifikasi. *F1-Score* merupakan rata-rata harmonis dari presisi dan *recall* yang memiliki nilai berkisar 0 sampai 1.

$$F1 - Score = 2 \times \frac{Recall \times Presisi}{Recall + Presisi} \quad (2.10)$$

VARIABLE IMPORTANCE

Variable importance adalah konsep dalam *machine learning* yang mengukur seberapa besar kontribusi masing-masing variabel terhadap prediksi model. Dalam model berbasis pohon keputusan, seperti *CatBoost*, *XGBoost*, dan *Random Forest*, *variable importance* sangat berguna untuk memahami bagaimana model membuat keputusan serta membantu dalam seleksi variabel untuk meningkatkan kinerja model (Syamkalla, 2024). *Variable importance* adalah metode untuk mengevaluasi seberapa besar pengaruh setiap variabel terhadap hasil prediksi dalam model *CatBoost*. Hal ini membantu dalam seleksi variabel, interpretasi model, dan peningkatan performa model. *CatBoost* memiliki beberapa metode untuk menghitung *variable importance* diantaranya adalah *Prediction Values Change* (Default), *Loss Function Change*, *Internal Variable Importance*, dan SHAP (*SHapley Additive exPlanations* (Barua, 2021)..

SHAPLEY ADDITIVE EXPLANATIONS (SHAP)

Salah satu pendekatan utama untuk meningkatkan interpretabilitas model adalah penggunaan SHAP (*SHapley Additive exPlanations*). Pendekatan *SHapley Additive Explanations* (SHAP) adalah metode yang memungkinkan untuk menginterpretasikan model prediksi pembelajaran mesin yang bersifat *blackbox* atau sulit dipahami (Parsa, 2021). Diperkenalkan oleh Lundberg dan Lee pada tahun 2017, nilai SHAP berakar pada teori permainan kooperatif (yang berkaitan dengan bagaimana sekelompok individu dapat bekerja sama untuk mencapai tujuan bersama) dan terinspirasi oleh karya peraih Nobel Lloyd Shapley (permatasari, 2022).

Tujuan dari SHAP adalah untuk menjelaskan prediksi dari variabel x dengan menghitung kontribusi dari setiap variabel terhadap

prediksi (Kannangara, 2022). Nilai-nilai variabel dari sebuah contoh data bertindak sebagai pemain dalam sebuah koalisi. Nilai *Shapley* mendistribusikan kontribusi prediksi secara adil di antara variabel-variabel. Seorang pemain dapat berupa nilai variabel individual, memungkinkan pemahaman yang lebih mendalam tentang faktor-faktor yang memengaruhi hasil prediksi. Perhitungan nilai *Shapley* melibatkan perataan kontribusi marjinal setiap pemain (atau variabel) di semua permutasi pemain yang potensial. Ini melibatkan penilaian setiap kemungkinan kombinasi variabel dan penentuan dampak yang dimiliki setiap variabel terhadap prediksi model saat disertakan dalam kombinasi ini. Dengan meratakan kontribusi ini di semua kemungkinan susunan variabel, maka dapat dicapai evaluasi yang seimbang dan dapat ditafsirkan mengenai pentingnya setiap variabel dalam prediksi model (Syamkalla, 2024). Pendekatan *SHapley Additive Explanations* (SHAP) menggunakan rumus sebagai berikut.

$$\phi_i = \sum_{S \subseteq \{1, \dots, p\} \setminus \{i\}} \frac{|S|!(p-|S|-1)!}{p!} \times [Val(S \cup \{i\}) - Val(S)] \quad (2.12)$$

Dengan,

ϕ_i : nilai *Shapley* dari anggota suatu variabel terhadap hasil prediksi.

$Val(S)$: output dari model yang dijelaskan dengan satu set variabel S .

p : jumlah keseluruhan variabel

METODE

Data yang digunakan dalam penelitian merupakan data sekunder yang diperoleh melalui situs resmi Badan Pusat Statistik (BPS) dari setiap provinsi di Indonesia berdasarkan kabupaten/kota pada tahun 2023. Jumlah data yang digunakan adalah sebanyak 514 sesuai dengan jumlah kabupaten/kota di Indonesia tahun 2023. Jenis data yang digunakan berupa data kategorik dan numerik yang terdiri dari 14 variabel.

Variabel yang digunakan dalam penelitian ini terdiri dari 1 (satu) variabel dependen (Y) dan 13 (tiga belas) variabel independen (X) yang dipilih berdasarkan masalah-masalah yang umum terjadi dalam dimensi pembentukan IPM dengan rincian penjelasan variabel dapat dilihat pada Tabel 3 berikut.

Tabel 3. Variabel Penelitian

Variabel	Keterangan	Jenis Data			
Status Wilayah (Y)	Status wilayah berupa maju, berkembang, tertinggal berdasarkan nilai IPM	Kategorik	Persentase rumah tangga dengan akses air bersih (X_7)	Tingkat akses terhadap sumber air layak konsumsi yang berdampak pada kesehatan masyarakat.	Numerik
Indeks keparahan kemiskinan (X_1)	Tingkat keparahan kemiskinan di suatu wilayah yang berdampak pada akses pendidikan, kesehatan, dan kesejahteraan ekonomi	Numerik	Persentase rumah tangga dengan sanitasi layak (X_8)	Akses terhadap fasilitas sanitasi yang mendukung kesehatan masyarakat.	Numerik
Rata-rata pengeluaran per kapita (X_2)	Indikator kesejahteraan masyarakat yang berhubungan dengan daya beli dan akses terhadap kebutuhan dasar	Numerik	Tingkat Pengangguran Terbuka (TPT) (X_9)	Proporsi angkatan kerja yang tidak memiliki pekerjaan, yang berdampak pada kesejahteraan ekonomi masyarakat.	Numerik
Jumlah fasilitas kesehatan (X_3)	Ketersediaan layanan kesehatan yang berpengaruh terhadap angka harapan hidup	Numerik	Tingkat Partisipasi Angkatan Kerja (TPAK) (X_{10})	Tingkat keterlibatan penduduk dalam aktivitas ekonomi yang berkontribusi pada pertumbuhan ekonomi wilayah.	Numerik
Persentase penduduk yang memiliki jaminan kesehatan (X_4)	Tingkat akses masyarakat terhadap layanan kesehatan yang terjangkau	Numerik	Wilayah 3T (X_{11})	Status wilayah sebagai Terdepan, Terluar, dan Tertinggal menunjukkan ketimpangan pembangunan. Status berupa Ya atau Tidak ^[56]	Kategorik
Indeks pembangunan literasi masyarakat (X_5)	Tingkat literasi berupa tinggi, sedang, rendah yang berpengaruh terhadap kualitas sumber daya manusia ^[55]	Kategorik	Pulau (X_{12})	Lokasi geografis wilayah administratif berupa pulau Sumatra, Jawa, Kalimantan, Sulawesi, Nusa Tenggara, Maluku, dan Papua dapat memengaruhi tingkat pembangunan dan akses layanan	Kategorik
Rata-rata lama sekolah (X_6)	Indikator IPM dalam dimensi pendidikan yang mencerminkan kualitas sumber daya manusia.	Numerik	Jenis Wilayah (X_{13})	Status administratif wilayah sebagai	Kategorik

Kabupaten atau
Kota yang
mencerminkan
tingkat
pembangunan dan
struktur
kewilayahan

Adapun tahapan dalam penelitian ini yaitu :

1. Pengumpulan data
Pada tahap ini, akan dilakukan pengumpulan data melalui situs resmi Badan Pusat Statistik (BPS) dari 38 provinsi di Indonesia yang mencakup nilai IPM dan 13 variabel yang berpengaruh terhadap IPM dan status kualitas hidup manusia berdasarkan kabupaten/kota di setiap provinsi tersebut.
2. *Preprocessing* data
Pada tahap ini, akan dilakukan persiapan pengolahan data sebelum dianalisis dan dilakukan pemodelan. Persiapan data dilakukan dengan beberapa tahap sebagai berikut.
 - a. Pengolahan data mentah
Pada tahap ini, data yang sudah dikumpulkan secara mentah akan diolah menggunakan perangkat lunak *Microsoft Excel*. Data diolah dengan terlebih dahulu mengubah variabel yang berisi nilai IPM menjadi variabel berupa kategori yaitu maju, berkembang, dan tertinggal. Pemberian kategori setiap wilayah didasari dengan *threshold* pengelompokan IPM yang dikutip dalam Kompas (2022) [23] sebagai berikut.
Kategori $IPM \geq 80$: Maju
Kategori $60 \leq IPM < 80$: Berkembang
Kategori $IPM < 60$: Tertinggal
 - b. Eksplorasi data
Pada tahap ini, akan dilakukan eksplorasi data yang mencakup statistika deskriptif, visualisasi data, struktur data, identifikasi data, dan pemeriksaan *missing value* dan *outlier*.
 - c. *Variable engineering*
Pada tahap ini, akan dilakukan modifikasi variabel berdasarkan tipe data yang disesuaikan dengan algoritma *CatBoost*. Algoritma *CatBoost* hanya membaca data yang memiliki tipe data; *float* (bilangan

desimal) dan *integer* (bilangan bulat) untuk variabel numerik, *string* dan *integer encoded* untuk variabel kategorik. Selanjutnya dilakukan pelabelan variabel kategorik pada variabel dependen (Y) atau target dan variabel independen (X). Variabel dependen dilabeli sesuai dengan kebutuhan saat pemodelan menggunakan *CatBoost* karena model akan lebih mudah memahami variabel target menggunakan pelabelan angka. Variabel independen dilabeli sesuai dengan kebutuhan saat interpretasi model menggunakan nilai SHAP karena SHAP lebih mudah memahami variabel kategorik dengan menggunakan label angka. Beberapa variabel kategorik dilabeli dengan sebagai berikut.

Tabel 4. Pelabelan Variabel Kategorik

Variabel	Label
Status Wilayah (Y)	Maju = 0
	Berkembang = 1
	Tertinggal = 2
Indeks Pembangunan Literasi Masyarakat (X_5)	Tinggi = 0
	Sedang = 1
	Rendah = 2
Wilayah 3T (X_{11})	Tidak = 0
	Ya = 1
Pulau (X_{12})	Sumatra = 0
	Jawa = 1
	Kalimantan = 2
	Sulawesi = 3
	Nusa Tenggara = 4
	Maluku = 5 Papua = 6
Jenis Wilayah (X_{13})	Kabupaten = 0
	Kota = 1

3. Pemodelan klasifikasi
Pada tahap ini, akan dilakukan pembentukan model klasifikasi kualitas hidup manusia menggunakan algoritma *CatBoost Classifier*. Proses pemodelan mengikuti prosedur standar oleh situs resmi algoritma *CatBoost* yaitu *CatBoost.ai* yang telah disesuaikan berdasarkan kebutuhan penelitian yaitu klasifikasi multikelas. Beberapa tahap yang diperlukan

untuk membangun model klasifikasi yaitu sebagai berikut.

a. Pembagian data *training* dan *testing*

Pada tahap ini, data akan dibagi menjadi data latih (*training*) dan data uji (*testing*). Pada penelitian ini, pembagian data akan dibagi menjadi data *training* sebanyak 80% data dan data *testing* sebanyak 20% data. Kemudian pada tahap pemodelan, dilakukan evaluasi model sementara dengan membandingkan *logloss* data *training* dan data *validation*. Data *validation* diambil dari 20% data *training* mengikuti standar umum dalam penerapan *machine learning* khususnya algoritma *CatBoost* dalam *CatBoost Documentation* (*catboost.ai*).

b. *Hyperparameter tuning*

Pada tahap ini, akan dilakukan pencarian atau penentuan kombinasi parameter yang akan digunakan dalam pelatihan model menggunakan algoritma *CatBoost*. Penentuan kombinasi akan dicoba menggunakan metode *Randomized Search*.

c. Pelatihan model

Pada tahap ini, model akan dilatih sampai menemukan model klasifikasi terbaik berdasarkan *tuning parameter* yang ditentukan.

d. Evaluasi kinerja model

Pada tahap ini, setelah model klasifikasi dibentuk maka dilakukan evaluasi berdasarkan *confusion matrix* untuk melihat akurasi, presisi, *recall*, *F1-Score*, dan performa dari model. Apabila hasil *confusion matrix* menunjukkan nilai yang baik maka model klasifikasi dapat dikatakan baik dan bisa digunakan dalam analisis selanjutnya. Namun, jika sebaliknya maka perlu dilakukan optimasi pada pelatihan model kembali.

4. Analisis hasil klasifikasi

Pada tahap ini, hasil prediksi model klasifikasi akan dianalisis dan akan dilakukan penentuan *variable importance* dari model klasifikasi menggunakan metode *Shapley Additive Explanations* (SHAP).

5. Interpretasi hasil dan kesimpulan


Setelah hasil klasifikasi dianalisis dan *variable importance* diperoleh, maka akan dilakukan

interpretasi dari hasil tersebut dan dibuat kesimpulan dari penelitian yang dilakukan.

HASIL DAN PEMBAHASAN

Eksplorasi Data

Kelompok wilayah berstatus maju terdiri dari wilayah yang memiliki nilai IPM lebih dari atau sama dengan angka 80,00 (nilai IPM ≥ 80). Kelompok wilayah berstatus berkembang terdiri dari wilayah dengan nilai IPM berada di kisaran angka 60,00 sampai 79,99 ($60 \leq$ nilai IPM < 80). Kelompok wilayah berstatus tertinggal terdiri dari wilayah dengan nilai IPM berada di bawah angka 60,00 (nilai IPM < 60). Pengolahan data IPM per kabupaten/kota dilakukan secara sederhana hasilnya dapat dilihat pada Gambar 4.1



Gambar 3. Grafik Jumlah Wilayah per Kelompok Status Wilayah Berdasarkan Pengelompokan IPM Gambar 3 di atas menunjukkan grafik banyaknya wilayah dari masing-masing kelompok status wilayah berdasarkan nilai IPM yang sudah dikelompokkan. Berdasarkan grafik tersebut dapat dilihat bahwa kelompok status wilayah dengan jumlah wilayah terbanyak adalah kelompok wilayah berstatus berkembang dengan jumlah wilayah sebanyak 438 wilayah. Kemudian diikuti dengan kelompok wilayah berstatus maju dengan jumlah wilayah sebanyak 59 wilayah. Sementara kelompok wilayah berstatus tertinggal memiliki jumlah wilayah sebanyak 17 wilayah.

Perbedaan yang cukup signifikan dari banyaknya wilayah masing-masing kelompok menunjukkan besarnya ketimpangan dari persebaran nilai IPM masing-masing wilayah kabupaten/kota di Indonesia. Mayoritas wilayah di Indonesia masih berstatus berkembang dan bahkan beberapa wilayah berstatus tertinggal, sementara

banyaknya wilayah wilayah maju tidak mencapai 20% dari total banyaknya wilayah kabupaten/kota di Indonesia. Oleh karena itu, analisis lanjutan dilakukan untuk mengetahui penyebab ketimpangan status wilayah tersebut. Sehingga dalam penelitian ini, variabel status wilayah menjadi variabel target atau dependen (Y).


Pemodelan Klasifikasi dengan Algoritma Catboost Classifier

Setelah *preprocessing* data, dilanjutkan dengan tahap pemodelan klasifikasi menggunakan algoritma *CatBoost Classifier*. Pemodelan dilakukan dengan terlebih dahulu membagi data menjadi data latih (*training*) dan data uji (*testing*). Pembagian data *training* dan data *testing* menggunakan rasio 80 : 20 yang artinya data *training* dibagi sebanyak 80% dari jumlah data yaitu sebanyak 411 data dan data *testing* sebanyak 20% dari jumlah data yaitu sebanyak 103 data. Data *training* digunakan untuk melatih model klasifikasi dan data *testing* digunakan untuk mengevaluasi performa dari model klasifikasi. Tahap selanjutnya dilakukan *hyperparameter tuning*, pelatihan model, dan evaluasi model sebagai berikut.

Tabel 1 *Hyperparameter Tuning* dari *Randomized Search*

<i>Hyperparameter</i>	Nilai
<i>iterations</i>	500
<i>learning_rate</i>	0,05
<i>depth</i>	4
<i>l2_leaf_reg</i>	5

Visualisasi dari proses pelatihan dapat dilihat dari perbandingan grafik penurunan nilai *logloss* antara data *training* dan data validasi (*validation*) pada Gambar 4 di bawah ini.



Gambar 4. Grafik Perbandingan *Logloss Train* dan *Validation Multiclass Model CatBoost*

Berdasarkan grafik pada Gambar 4 di atas, sumbu horizontal menunjukkan jumlah iterasi (hingga 500 iterasi), sedangkan sumbu vertikal menunjukkan nilai *logloss* yang diperoleh. Berdasarkan grafik tersebut, terlihat bahwa nilai *logloss* untuk data pelatihan dan validasi menunjukkan penurunan yang signifikan hingga sekitar iterasi ke-100, kemudian penurunan mulai melambat dan cenderung mendatar setelah iterasi ke-200. Hal ini mengindikasikan bahwa model mampu belajar dengan baik (cepat dan efektif) pada tahap awal pelatihan. Pada iterasi selanjutnya, nilai *logloss* pada data *training* (garis biru) terus mengalami penurunan yang konsisten, sedangkan nilai *logloss* pada data validasi (garis oranye) juga menurun, namun dengan selisih yang sedikit lebih tinggi. Hal ini menunjukkan bahwa model memiliki generalisasi yang baik, tanpa gejala *overfitting* yang signifikan. *Overfitting* umumnya ditandai dengan divergensi antara *logloss* pelatihan dan validasi, di mana *logloss* pelatihan terus turun tetapi *logloss* validasi meningkat tajam.

Evaluasi Kinerja Model

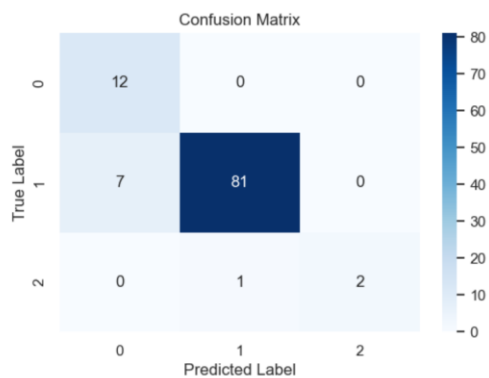
Setelah pelatihan model, maka dilanjutkan dengan evaluasi akhir dari kinerja model tersebut dengan menggunakan data *testing* berdasarkan metrik evaluasi berupa *confusion matrix* dan nilai ROC-AUC. Berikut merupakan hasil terbaik yang dicapai dalam pemodelan menggunakan *CatBoost Classifier* yang dapat dilihat dalam *classification report* pada Tabel 6 dan ilustrasi *confusion matrix* pada Gambar 5 :

Tabel 6. *Classification Report*

<i>Class</i>	<i>Accur acy</i>	<i>Precisi on</i>	<i>Rec all</i>	<i>F1-Sco re</i>	<i>Supp ort</i>
Maju (0)		63%	100%	77%	12
Berkembang (1)	92,23%	99%	92%	95%	88
Tertinggal (2)		100%	67%	80%	3

Hasil klasifikasi menggunakan pemodelan *CatBoost Classifier* menghasilkan keakuratan model data

testing sebesar 0,9223 atau 92,23% yang menjelaskan bahwa pengklasifikasi *CatBoost* dapat memprediksi label kelas dengan benar sebesar 92,23% dari data yang dimasukkan. Dengan kata lain, jika model diberi data baru maka diharapkan dapat memprediksi dengan benar label kelas sekitar 92,23% dari data tersebut.



Gambar 5. Confusion Matrix

Gambar 5 di atas merupakan *confusion matrix* dari pemodelan *CatBoost* yang menyatakan jumlah wilayah yang benar dan salah diklasifikasikan berdasarkan realita terhadap prediksi yang dijelaskan dalam TP (*True Positive*), FP (*False Positive*), TN (*True Negative*), dan FN (*False Negative*) dari setiap kelas dengan setiap warna berbeda menyatakan tingkat jumlah wilayah yang berbeda (semakin banyak jumlahnya maka semakin biru).


Model memiliki kinerja yang sangat baik dalam mengenali kategori 'Berkembang', yang merupakan mayoritas kelas. Hal ini terlihat dari nilai *True Positive* (TP) yang tinggi (81) dan *False Negative* (FN) serta *False Positive* (FP) yang rendah. Namun, untuk kelas 'Tertinggal', akurasi masih perlu ditingkatkan karena data dari kelas ini relatif sedikit (hanya 3 data). Ini menyebabkan model mengalami kesulitan dalam mengenali pola dari kelas minoritas, yang tercermin dari hanya 2 data yang diklasifikasikan benar (TP = 2) dan satu data diklasifikasikan salah (FN = 1). Sementara itu, kelas 'Maju' memiliki performa yang cukup baik dengan TP = 12 dan tidak ada FN, meskipun masih terdapat FP = 7, yang berarti terdapat beberapa wilayah

'Berkembang' yang diklasifikasikan keliru sebagai 'Maju'.

Analisis Klasifikasi Model dengan SHAP Values

Setelah dilakukan pemodelan klasifikasi dengan algoritma *CatBoost Classifier*, maka dilakukan interpretasi terhadap model berupa penentuan *variable importance* atau variabel kepentingan guna mengetahui sejauh mana kontribusi masing-masing variabel dalam memengaruhi hasil klasifikasi.

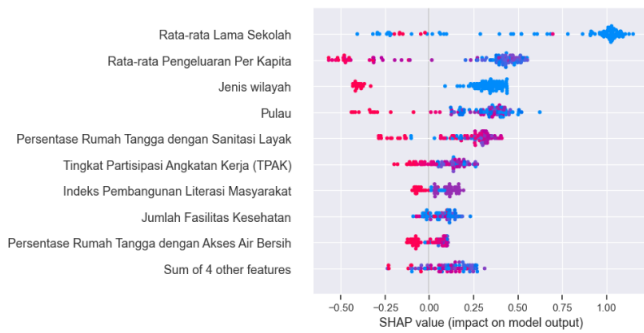
visualisasi *beeswarm plot* oleh SHAP yang menjelaskan kontribusi masing-masing variabel terhadap prediksi model klasifikasi ke dalam kelas 'Maju' pada status wilayah berdasarkan kualitas hidup manusia. Nilai SHAP menunjukkan seberapa besar suatu variabel mendorong prediksi menuju atau menjauhi kelas 'Maju'. Arah ke kanan (positif) artinya variabel tersebut berkontribusi positif mendorong prediksi ke kelas 'Maju', sedangkan arah ke kiri (negatif) berarti mendorong menjauhi kelas tersebut (menuju kelas 'Berkembang' atau 'Tertinggal'). Warna pada setiap titik menunjukkan besar kecilnya nilai variabel : warna merah berarti nilai variabel tinggi, sedangkan warna biru berarti nilai variabel rendah.



Gambar 1. Grafik *Beeswarm Plot* SHAP untuk Kelas Maju


Rata-rata Pengeluaran Per Kapita dan Rata-rata Lama Sekolah menjadi variabel yang paling berkontribusi dalam prediksi. Titik-titik biru yang berada di sisi kiri (negatif) menunjukkan bahwa wilayah dengan rata-rata lama sekolah dan Rata-rata Pengeluaran Per Kapita yang rendah cenderung menjauhi wilayah dari prediksi kelas ini. Sebaliknya, titik-titik merah di kanan (positif) menunjukkan bahwa wilayah dengan rata-rata lama sekolah yang tinggi sangat mendorong prediksi ke kelas 'Maju'. Pada variabel jenis wilayah

menunjukkan bahwa wilayah yang berstatus sebagai kota lebih berpeluang untuk diklasifikasikan ke dalam kelas 'Maju'.



Gambar 7. Grafik Beeswarm Plot SHAP untuk Kelas Berkembang

Rata rata lama sekolah dan rata rata pengeluaran perkapita memiliki distribusi SHAP yang lebar dan menjadi kontributor paling signifikan. Nilai SHAP positif dengan nilai variabel rendah di sisi kanan menunjukkan bahwa wilayah dengan rata-rata lama sekolah dan pengeluaran perkapita rendah (warna biru) mendorong prediksi ke arah kelas 'Berkembang'. Sebaliknya, nilai lama sekolah yang tinggi (warna merah) memiliki kemungkinan lebih kecil untuk diklasifikasikan sebagai 'Berkembang'. Variabel jenis wilayah menunjukkan distribusi yang cukup lebar. Titik-titik tersebar di sekitar nol, namun banyak yang mengarah ke kanan (positif), yang menunjukkan bahwa wilayah kabupaten yang dilabeli dengan angka 0 (nilai rendah; biru) cenderung diklasifikasikan sebagai 'Berkembang', sedangkan wilayah kota yang dilabeli dengan angka 1 (nilai tinggi; merah) memiliki kemungkinan lebih kecil untuk berada di kelas ini.



Gambar 8. Grafik Beeswarm Plot SHAP untuk Kelas Tertinggal

Titik-titik dengan nilai rata-rata lama sekolah yang rendah (warna biru) sedikit mendorong prediksi wilayah ke kelas 'Tertinggal' dengan nilai SHAP negatif yang sedikit mendekati 0 atau positif. Kemudian, nilai SHAP negatif yang tinggi (jauh ke kiri) berwarna merah, menunjukkan bahwa wilayah dengan lama sekolah tinggi secara kuat mengurangi kemungkinan masuk kelas tertinggal. Interpretasi ini menunjukkan bahwa rendahnya akses dan pencapaian pendidikan merupakan ciri wilayah tertinggal. Wilayah yang terletak di pulau yang dilabeli dengan angka (4, 5, dan 6) seperti Nusa Tenggara, Maluku, dan Papua (merah) memiliki nilai SHAP lebih positif dan mendorong prediksi wilayah ke kelas 'Tertinggal' dibandingkan dengan wilayah di pulau dengan label angka (0, 1, 2, dan 3) seperti Sumatra, Jawa, Kalimantan, dan Sulawesi (biru dan ungu). Dengan demikian, wilayah geografis seperti Papua, Maluku, dan Nusa Tenggara memiliki probabilitas lebih besar untuk termasuk kategori tertinggal. Hal ini mengindikasikan bahwa faktor geospasial dan keterpencilan wilayah menjadi penentu utama dalam ketertinggalan pembangunan. Persentase Rumah Tangga dengan Sanitasi Layak dengan nilai biru (sanitasi rendah) muncul dominan di sisi kanan, mendorong klasifikasi ke kelas 'Tertinggal'. Sebaliknya, titik merah (sanitasi tinggi) cenderung berada di sisi kiri (negatif), yang mengurangi peluang masuk ke kelas 'Tertinggal'. Hal ini menunjukkan bahwa akses terhadap sanitasi yang layak adalah indikator penting dalam membedakan wilayah tertinggal dengan yang tidak.

PEMBAHASAN

Berdasarkan hasil analisis nilai SHAP, dapat diketahui bahwa masing-masing kelas wilayah (maju, berkembang, dan tertinggal) memiliki variabel yang paling berkontribusi dalam proses klasifikasi, dengan rata-rata lama sekolah (X_6) sebagai faktor yang paling berpengaruh terhadap kualitas hidup manusia di ketiga kelas wilayah tersebut. Hal ini menunjukkan pentingnya peningkatan kualitas pendidikan di setiap wilayah berdasarkan lamanya pendidikan, yang idealnya minimal mencakup jenjang pendidikan dasar hingga menengah atas (SMA), bahkan hingga perguruan

tinggi. Pendidikan yang lebih lama merupakan investasi jangka panjang yang dapat memberikan manfaat yang signifikan bagi kualitas hidup manusia seperti meningkatkan keterampilan, pengetahuan, dan peluang kerja, yang pada akhirnya berkontribusi pada pendapatan yang lebih tinggi, kesehatan yang lebih baik, dan kesejahteraan secara keseluruhan.

Pada kelas wilayah maju dan berkembang, rata-rata pengeluaran per kapita (X_2) dan jenis wilayah (X_{13}) menjadi variabel yang juga berpengaruh terhadap kualitas hidup wilayahnya. Faktor ini menunjukkan bahwa wilayah penduduk dengan pengeluaran yang cukup tinggi umumnya memiliki kemampuan daya beli yang cukup baik, dan jika dikaitkan dengan jenis wilayah, wilayah kota umumnya cenderung memiliki pengeluaran yang lebih tinggi dibanding wilayah kabupaten [7]. Dengan kata lain, jika dikaitkan dengan pendidikan, wilayah dengan pengeluaran per kapita yang tinggi (kota) berkemungkinan besar mampu menerima pendidikan yang baik dari segi ekonomi. Sehingga, hal ini dapat menjadi wawasan bagi pemerintah untuk melakukan penganggaran biaya pendidikan yang disesuaikan dengan pengeluaran atau kemampuan daya beli setiap wilayah.

Kemudian pada kelas 'Tertinggal', selain pendidikan, terdapat variabel pulau (X_{12}) dan persentase rumah tangga dengan akses sanitasi layak (X_8) yang juga berpengaruh terhadap kualitas hidup setiap wilayah. Hal ini menunjukkan bahwa terdapat pulau yang harus menjadi prioritas dalam pembangunan wilayah yang maju. Berdasarkan interpretasi nilai SHAP, pulau-pulau timur di Indonesia seperti Papua dan Maluku mendorong prediksi wilayah dikatakan sebagai tertinggal, oleh karena itu perlu dieksplorasi penyebab pulau di bagian timur terindikasi wilayah tertinggal. Berdasarkan latar belakang masalah, diketahui bahwa adanya masalah keterbatasan pelayanan atau fasilitas kesehatan dan sanitasi yang kerap terjadi di Indonesia bagian timur. Masalah tersebut dapat menjadi salah satu faktor yang menyebabkan pulau bagian timur menjadi faktor yang paling berpengaruh dalam pengklasifikasian wilayah tertinggal. Hal ini juga dapat dilihat dari hasil interpretasi SHAP untuk setiap kelas dimana variabel Jumlah Fasilitas Kesehatan (X_3) juga termasuk variabel yang memberi pengaruh kualitas

hidup manusia di setiap wilayah. Dimana jumlah fasilitas kesehatan yang tersebar tidak merata di setiap wilayah yang mengartikan bahwa terdapat ketimpangan dalam segi infrastruktur dalam dimensi kesehatan.

Berdasarkan perspektif risiko sosial, penelitian ini menunjukkan bahwa ketimpangan dalam variabel-variabel indikator seperti pendidikan, standar hidup layak, dan kesehatan yang tidak hanya berdampak pada klasifikasi pembangunan wilayah, tetapi juga berkontribusi terhadap pembentukan risiko-risiko sosial jangka panjang. Wilayah dengan pendidikan rendah dan sanitasi yang buruk memiliki kerentanan lebih tinggi terhadap penyakit, pengangguran, dan ketergantungan sosial yang pada akhirnya dapat meningkatkan beban klaim dalam sistem jaminan sosial, asuransi kesehatan, dan dana pensiun bagi beberapa perusahaan pemberi jaminan [12].

PENUTUP

SIMPULAN

Model klasifikasi menggunakan algoritma *CatBoost Classifier* dengan *hyperparameter tuning* menggunakan *Randomized Search* memiliki kinerja yang sangat baik dengan akurasi sebesar 92,23% dalam mengenali wilayah kelas 'Berkembang', yang merupakan mayoritas kelas. Hal ini terlihat dari nilai *True Positive* (TP) yang tinggi (81) dan *False Negative* (FN) serta *False Positive* (FP) yang rendah. Namun, untuk kelas 'Tertinggal', akurasi masih perlu ditingkatkan karena data dari kelas ini relatif sedikit (hanya 3 data). Ini menyebabkan model mengalami kesulitan dalam mengenali pola dari kelas minoritas, yang terlihat dari hanya 2 data yang diklasifikasikan benar (TP = 2) dan satu data diklasifikasikan salah (FN = 1). Sementara itu, kelas 'Maju' memiliki performa yang cukup baik dengan TP = 12 dan tidak ada FN, meskipun masih terdapat FP = 7, yang berarti terdapat beberapa wilayah 'Berkembang' yang diklasifikasikan keliru sebagai 'Maju'.

Berdasarkan nilai SHAP, masing – masing kelas memiliki *variable importance* yang paling berkontribusi dalam klasifikasi wilayah. Pada kelas 'Maju' terdapat 3

variabel paling berkontribusi yaitu rata-rata lama sekolah (X_6), rata-rata pengeluaran per kapita (X_2), dan jenis wilayah (X_{13}). Pada kelas 'Berkembang' terdapat 3 variabel paling berkontribusi yaitu rata-rata lama sekolah (X_6), rata-rata pengeluaran per kapita (X_2), dan jenis wilayah (X_{13}). Hal ini menunjukkan bahwa peningkatan pendidikan formal, daya beli masyarakat, dan karakteristik geografis memiliki peran dalam mendorong wilayah mencapai status pembangunan yang lebih tinggi. Sementara pada kelas 'Tertinggal' terdapat 3 variabel paling berkontribusi yaitu rata-rata lama sekolah (X_6), pulau (X_{12}), dan persentase rumah tangga dengan sanitasi layak (X_8). Hal ini mencerminkan bahwa selain pendidikan, keterisolasian geografis, dan keterbatasan infrastruktur kesehatan seperti sanitasi menjadi faktor utama pendorong keterbelakangan wilayah.

DAFTAR PUSTAKA

- Daftar pustaka disusun menggunakan aplikasi Refernce Management Software seperti Mendeley, Zotero, Endnote dll.
- Sutikno, A. N. (2020). Bonus demografi di Indonesia. *Visioner: Jurnal Pemerintahan Daerah*, 12(2), 421–439.
- Puspa. (2023). Transformasi pendidikan abad ke-21 dalam merealisasikan sumber daya manusia unggul menuju Indonesia Emas 2045. *Jurnal Basicedu*, 7(5), 3309–3321.
- Novrizaldi. (2022, October 6). *Indonesia Emas 2045 diwujudkan oleh generasi muda*. Kementerian Koordinator Bidang Pembangunan Manusia dan Kebudayaan. <https://www.kemendikbud.go.id/indonesia-emas-2045-diwujudkan-oleh-generasi-muda>
- World Health Organization. (2022). *Measuring quality of life (WHOQOL)*. <https://www.who.int/tools/whoqol>
- Badan Pusat Statistik. (2024). *Profil kemiskinan di Indonesia September 2023*. <https://www.bps.go.id>
- Badan Pusat Statistik. (2024). *Statistik kesehatan Indonesia 2023*. <https://www.bps.go.id>
- UNESCO. (2022). *Global education monitoring report 2022: Indonesia country profile*. <https://en.unesco.org/gem-report>
- UNICEF, & World Health Organization. (2023). *Progress on household drinking water, sanitation and hygiene 2023 update and SDG baselines*. <https://washdata.org>
- International Labour Organization. (2020). *Indonesia employment diagnostic study*. <https://www.ilo.org>
- Nayottama, H. (2023, July 24). *Indonesia masih menghadapi tantangan dalam memperluas cakupan dan efektivitas program perlindungan sosial*. Fakultas Ekonomi dan Bisnis Universitas Gadjah Mada. <https://feb.ugm.ac.id/id/berita/4190-indonesia-masih-menghadapi-tantangan-dalam-memperluas-cakupan-dan-efektivitas-program-perindungan-sosial>
- Hancock, J. T. (2020). CatBoost for big data: An interdisciplinary review. *Journal of Big Data*, 7(94).
- Pahlevi, O. (2024). Model klasifikasi risiko stunting pada balita menggunakan algoritma CatBoost classifier. *Bulletin of Computer Science Research*, 6(4), 414–421.
- Syamkalla Teddy, K. S. (2024). Implementasi algoritma CatBoost dan Shapley additive explanations (SHAP) dalam memprediksi popularitas game indie pada platform Steam. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, 11(4), 771–776.
- Jacob, S. (2018). Faktor-faktor yang mempengaruhi kualitas hidup masyarakat Karubaga District/Sub-District Tolikara Provinsi Papua. *Jurnal Nasional Ilmu Kesehatan (JNIK)*, 1.
- World Health Organization. (1998). *WHOQOL: Programme on mental health, division of mental*

health and prevention of substance abuse. World Health Organization.

Explanations Method," *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 14, nr 4, pp. 1052-1063, 2022.

Diener, E. (1999). Subjective well-being: Three decades of progress. *Psychological Bulletin*, 125(2), 276-302.

Pamungkas, C. A. (2022). Klasifikasi indeks pembangunan manusia di Indonesia tahun 2022 dengan support vector machine. *JUISIK*, 2(3).

Santoso, D. (2024). *Indeks pembangunan manusia 2023*. Badan Pusat Statistik.

Hadiana, A. F. (2023). Prediksi curah hujan menggunakan metode categorical boosting (CatBoost). *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(4), 2930-2937.

Syamkalla Teddy, K. S. (2024). Implementasi algoritma CatBoost dan Shapley additive explanations (SHAP) dalam memprediksi popularitas game indie pada platform Steam. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 11(4), 771-776.

Prokhorenkova, L. (2017). *CatBoost: Unbiased boosting with categorical feature*. Yandex.

Barua, D. G. S. (2021). *Swindle: Predicting the probability of loan defaults using CatBoost algorithm*. In *Proceedings of the Fifth International Conference on Computing Methodologies and Communication (ICCMC 2021)* (pp. 1710-1715). IEEE.

Parsa, B. (2019). Toward safer highways: Application of XGBoost and SHAP for real-time accident detection and feature analysis. *Accident Analysis & Prevention*.

Permatasari, N. (2022). Predicting diabetes mellitus using CatBoost classifier and Shapley additive explanations (SHAP) approach. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 16(2), 615-624.

K. Kannangara, "Investigation of Feature Contribution to Shield Tunneling-Induced Settlement Using Shapley Additive