



Optimasi Prediksi Hipertensi Menggunakan Logistic Regression Berbasis Borderline SMOTE dan Penjelasan Model dengan SHAP

Risky Radison Nasution^{1*}, Kurniabudi², Dodo Zaenal Abidin³

¹⁻³ Departemen Sistem Informasi, Fakultas Ilmu Komputer, Institusi Universitas Dinamika Bangsa, Negara Indonesia

Email: riskyradisonnasution@gmail.com^{1*}, kurniabudi@unama.ac.id², dodozaenalabidin@gmail.com³

Alamat: Jalan Jendral Sudirman Thehok - Jambi 36138

*Penulis Korespondensi: riskyradisonnasution@gmail.com

Abstract. Hypertension is a major global health risk that requires accurate early detection, yet conventional methods struggle with complex and imbalanced health datasets. This study aims to optimize hypertension prediction using a Logistic Regression model integrated with Borderline-SMOTE to enhance recall and provide model transparency through SHAP (Shapley Additive Explanations). The method utilizes the BRFSS dataset, applying Borderline-SMOTE to address class imbalance at the decision boundary and XAI techniques for global and local interpretation. The findings show that the model achieved an accuracy of 0.719, an AUC of 0.800, and a significantly improved recall of 0.756. SHAP analysis identified age, high cholesterol, and BMI as the most influential risk factors, while waterfall plots successfully clarified individual risk extremes, ranging from 1.72% to 99.43% probability. These results imply that the proposed approach provides a sensitive and transparent screening tool for public health practitioners, effectively balancing statistical efficiency with clinical accountability.

Keywords: Borderline-SMOTE; Explainable Artificial Intelligence; Hypertension; Logistic Regression; SHAP

Abstrak. Hipertensi merupakan risiko kesehatan global utama yang memerlukan deteksi dini yang akurat, namun metode konvensional menghadapi kendala pada kumpulan data kesehatan yang kompleks dan tidak seimbang. Penelitian ini bertujuan untuk mengoptimalkan prediksi hipertensi menggunakan model Logistic Regression yang diintegrasikan dengan Borderline-SMOTE untuk meningkatkan nilai recall serta memberikan transparansi model melalui SHAP (Shapley Additive Explanations). Metode yang digunakan melibatkan dataset BRFSS, menerapkan Borderline-SMOTE untuk menangani ketidakseimbangan kelas pada batas keputusan dan teknik XAI untuk interpretasi global serta lokal. Temuan menunjukkan bahwa model mencapai akurasi 0,719, AUC 0,800, dan meningkatkan recall secara signifikan menjadi 0,756. Analisis SHAP mengidentifikasi usia, kolesterol tinggi, dan BMI sebagai faktor risiko yang paling berpengaruh, sementara waterfall plot berhasil menjelaskan ekstremitas risiko individu dengan rentang probabilitas 1,72% hingga 99,43%. Implikasi dari penelitian ini adalah tersedianya alat skrining yang sensitif dan transparan bagi praktisi kesehatan masyarakat yang mampu menyeimbangkan efisiensi statistik dengan pertanggungjawaban klinis.

Kata kunci: Borderline-SMOTE; Explainable Artificial Intelligence; Hipertensi; Logistic Regression; SHAP

1. LATAR BELAKANG

Hipertensi merupakan tantangan kesehatan global yang memicu risiko serius seperti penyakit jantung dan gagal ginjal (Touyz, 2022). Dengan proyeksi penderita hipertensi mencapai 1,5 miliar pada tahun 2025 (Mashuri et al., 2022). Metode deteksi konvensional mulai menghadapi keterbatasan waktu dan jangkauan, sehingga penggunaan *machine learning* menjadi sangat urgensi untuk mengenali pola risiko pada data multidimensional secara akurat (Martinez-Ríos et al., 2021).

Dalam pemodelan kesehatan, algoritma *ensemble* seperti XGBoost sering kali unggul secara statistik (AUC) (Chen et al., 2022), namun *Logistic Regression* tetap menjadi *baseline* penting karena stabilitas dan risiko *overfitting* yang rendah (AlKaabi et al., 2020). Dalam konteks medis, metrik sensitivitas (*recall*) menjadi prioritas utama dibandingkan sekadar akurasi global. Hal ini didasari pada prinsip bahwa kegagalan mendeteksi pasien sakit (*false negative*) memiliki konsekuensi klinis yang jauh lebih fatal daripada salah mengklasifikasikan orang sehat sebagai sakit (*false positive*) (Layton, 2024; Montagna et al., 2022). Oleh karena itu, peningkatan *false positive* dianggap sebagai kompromi yang rasional dalam prosedur skrining massal guna memastikan tidak ada kasus hipertensi yang terlewat.

Kesenjangan penelitian saat ini menunjukkan bahwa meskipun *Logistic Regression* unggul dalam transparansi dan stabilitas, model statistik ini cenderung memiliki performa lebih rendah (AUC sekitar 60%) pada data yang kompleks jika tidak dioptimalkan secara khusus terhadap karakteristik distribusi kelas (Bisong et al., 2024; Si et al., 2025). Masalah ketidakseimbangan kelas pada dataset besar seperti *Behavioral Risk Factor Surveillance System* (BRFSS) dapat menyebabkan model kurang sensitif dalam mendeteksi kasus positif yang justru paling kritis secara klinis (Aiosa et al., 2023; Khan et al., 2024). Oleh karena itu, penelitian ini menjadikan metrik sensitivitas sebagai prioritas utama dalam pemilihan dan penyetelan model, sementara penurunan spesifisitas diterima sebagai kompromi yang rasional. Untuk mencapai hal tersebut, teknik Borderline-SMOTE ditawarkan sebagai inovasi untuk memperkaya data sintesis tepat pada perbatasan antara kelas mayoritas dan minoritas, sehingga meningkatkan kemampuan *Logistic Regression* dalam membedakan kasus hipertensi yang sulit diklasifikasikan (Hashimoto-Roth et al., 2022).

Penggunaan SHAP (*Shapley Additive Explanations*) dalam penelitian ini bertujuan untuk mengoptimalkan penjelasan model *Logistic Regression*. SHAP memberikan kontribusi yang adil dari setiap fitur terhadap hasil prediksi, sehingga menjembatani kebutuhan akan akurasi tinggi dan transparansi yang dibutuhkan oleh praktisi kesehatan masyarakat (Bifarin, 2023).

Berdasarkan permasalahan tersebut, tujuan dari penelitian ini adalah untuk mengoptimalkan performa prediksi hipertensi menggunakan algoritma *Logistic Regression* melalui implementasi teknik Borderline-SMOTE guna meningkatkan nilai *recall*. Selain itu, penelitian ini bertujuan untuk memberikan penjelasan model secara mendalam menggunakan SHAP dalam mengidentifikasi kontribusi faktor risiko. Melalui penggabungan efisiensi statistik *Logistic Regression*, presisi *Borderline-SMOTE*, dan

kedalaman interpretasi SHAP penelitian ini diharapkan mampu menghasilkan model prediksi yang sensitif, transparan, dan dapat dipertanggungjawabkan secara klinis.

2. KAJIAN TEORITIS

Machine Learning (ML) adalah proses pembelajaran otomatis di mana algoritma belajar langsung dari data untuk menemukan representasi input dan memprediksi output tanpa pengkodean eksplisit (Di Franco & Santurro, 2021). Dalam sektor kesehatan, ML berperan penting dalam analitik prediktif dan pengobatan yang dipersonalisasi melalui pemrosesan data medis yang kompleks untuk meningkatkan hasil perawatan pasien serta mempercepat pengembangan pengobatan (Kumari et al., 2023).

Hipertensi arterial didefinisikan sebagai kondisi tekanan darah sistolik-diastolik yang secara berkelanjutan mencapai atau melebihi 140/90 mmHg berdasarkan minimal tiga kali pengukuran pada hari yang berbeda, termasuk pada pasien dengan terapi antihipertensi yang menunjukkan angka normal (Sellén Crombet, 2008). Karena memiliki penyebab yang beragam, pengelolaan hipertensi memerlukan pendekatan personal karena sering kali tidak dapat diidentifikasi hanya melalui satu faktor tunggal (Weir, 2010).

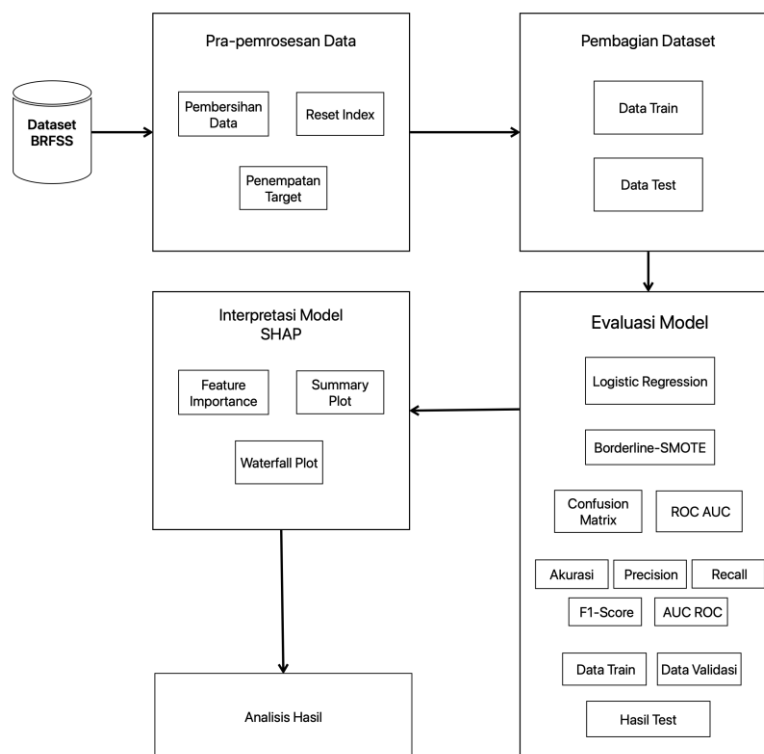
Logistic Regression adalah metode statistik untuk memodelkan hubungan antara satu atau lebih variabel independen terhadap variabel dependen dikotomis atau biner (Jr et al., 2013; Trevisan et al., 2023). Metode ini berfungsi untuk memperkirakan probabilitas suatu peristiwa pada data kategoris serta memungkinkan interpretasi koefisien melalui rasio odds, sehingga sangat berguna dalam memprediksi hasil di bidang kedokteran, ilmu sosial, dan pemasaran (Vera, 2022).

Balancing data merupakan tahapan penting dalam *data mining* untuk menangani distribusi kelas yang tidak seimbang melalui teknik *oversampling* atau *undersampling* agar proporsi kelas menjadi lebih seimbang (Han & Kamber, 2012). Salah satu modifikasinya Borderline-SMOTE secara spesifik berfokus menghasilkan sampel sintetis bagi kelas minoritas di sekitar batas keputusan (*decision boundary*) yang memisahkan kelas minoritas dan mayoritas. Dengan memperkuat representasi pada area perbatasan tersebut, teknik ini terbukti sangat efektif dalam meningkatkan performa klasifikasi pada kumpulan data yang tidak seimbang (Sovia et al., 2024).

Explainable Artificial Intelligence (XAI) merupakan kumpulan teknik dan strategi yang dirancang untuk memberikan penjelasan transparan terhadap keputusan model pembelajaran mesin guna meningkatkan akuntabilitas dan kepercayaan pengguna (Ridley, 2022). Salah satu metode XAI yang dominan adalah *Shapley Additive Explanations* (SHAP) yang menggunakan pendekatan teori permainan untuk mengonversi keputusan model yang kompleks menjadi skor kontribusi fitur yang mudah dipahami, sehingga membantu membuka sifat "kotak hitam" pada domain yang sensitif. Meskipun menawarkan keunggulan sistematis dalam mengukur kontribusi fitur, SHAP memiliki keterbatasan berupa kompleksitas komputasi yang tinggi serta risiko interpretasi yang tidak akurat pada data yang kolinear, sehingga pengguna perlu memahami keterbatasan tersebut untuk menghindari penyalahgunaan pada aplikasi krusial (Salih et al., 2023).

3. METODE PENELITIAN

Penelitian ini menggunakan kerangka kerja berbasis proses *machine learning* dalam membangun model prediksi risiko hipertensi. Alur eksperimen ini menjelaskan langkah-langkah teknis dalam membangun, menguji, dan mengevaluasi model prediksi hipertensi berbasis machine learning pada dataset BRFSS 2015 secara mendalam.



Gambar 1. Alur Eksperimen.

Dataset BRFSS

Penelitian ini menggunakan dataset *Behavioral Risk Factor Surveillance System* (BRFSS) 2015 yang diperoleh dari sumber resmi *Centers for Disease Control and Prevention* (CDC).

Pra-pemrosesan Data

Pada tahap awal, data BRFSS diproses agar layak digunakan dalam pemodelan *machine learning* melalui pembersihan data dengan menghapus nilai hilang pada variabel target serta menyaring data tidak valid pada variabel biner dan ordinal untuk meminimalkan noise dan bias, kemudian dilakukan pengaturan ulang indeks dataset agar konsisten dan mudah ditelusuri, serta penempatan variabel target (HighBP) secara tepat guna mendukung proses klasifikasi pada tahap pelatihan dan evaluasi.

Pembagian Dataset

Data hasil pra-pemrosesan dibagi menjadi data pelatihan (train) dan data pengujian (test) dengan skema 80:20 untuk menguji generalisasi model pada data baru.

Evaluasi Model

Evaluasi Model ini dimulai dengan pemisahan 20% data uji (*test set*) yang dijaga independensinya dari seluruh proses pelatihan dan validasi. Untuk mencegah *data leakage* dan estimasi performa yang terlalu optimistis, teknik penyeimbangan kelas seperti Borderline SMOTE hanya diterapkan pada data pelatihan (*train set/fold*), sementara data validasi dan uji tetap terjaga orisinalitasnya agar mencerminkan kondisi klinis yang sebenarnya (Badriyah et al., 2025; Bradshaw et al., 2023; Liang et al., 2024). Kualitas model kemudian dinilai berdasarkan rata-rata metrik evaluasi melalui *cross validation* untuk menjamin independensi hasil, sebelum akhirnya diuji kembali menggunakan algoritma Logistic Regression dan teknik *oversampling* terpilih pada data uji yang telah dipisahkan di awal.

Interpretasi Model

Setelah memperoleh hasil pelatihan, validasi, dan pengujian akhir, model Logistic Regression berbasis Borderline-SMOTE diinterpretasikan menggunakan SHAP dengan metode *Permutation Explainer*. Dalam proses ini, *Feature Importance* digunakan untuk memvisualisasikan peringkat pengaruh variabel utama pada seluruh data, sementara *Summary Plot* SHAP menyajikan gambaran kontribusi fitur secara global pada masing-masing skenario, yang kemudian dilengkapi dengan *Waterfall Plot* SHAP untuk melakukan interpretasi lokal terhadap prediksi pada tingkat individu.

Analisis Hasil

Seluruh hasil evaluasi dan interpretasi dianalisis untuk memperoleh insight penting seperti faktor risiko utama hipertensi.

4. HASIL DAN PEMBAHASAN

Hasil Train dan Validasi Penelitian

Tabel 1. Hasil Rata-rata Train dan Validasi.

Resamplers	Rata-Rata Fold	Accuracy	Precision	Recall	F1	AUC
Tanpa Borderline SMOTE	Train	0,724	0,697	0,631	0,662	0,795
	Validasi	0,723	0,697	0,630	0,662	0,795
Dengan Borderline SMOTE	Train	0,716	0,646	0,751	0,694	0,795
	Validasi	0,716	0,646	0,751	0,694	0,795

Fase pelatihan dan validasi dalam eksperimen ini menunjukkan bahwa penerapan Borderline-SMOTE pada model Logistic Regression berhasil mencapai target utama penelitian yaitu optimasi nilai Recall (Sensitivitas). Skor *Recall* yang tinggi menunjukkan bahwa model mampu secara efektif meminimalkan angka *False Negative* yang selaras dengan prioritas klinis untuk memastikan penderita hipertensi tidak luput dari deteksi awal. Meskipun hasil evaluasi menunjukkan adanya penurunan pada skor spesifisitas sebagai bentuk kompromi yang rasional demi sensitivitas, stabilitas skor AUC dan akurasi selama *k-fold cross validation* mengonfirmasi bahwa model tetap memiliki performa yang andal. Konsistensi skor antara tahap pelatihan dan validasi juga membuktikan bahwa teknik penyeimbangan data pada perbatasan kelas (*borderline*) berhasil memperkuat kemampuan prediksi model terhadap kelas minoritas tanpa menyebabkan *overfitting*.

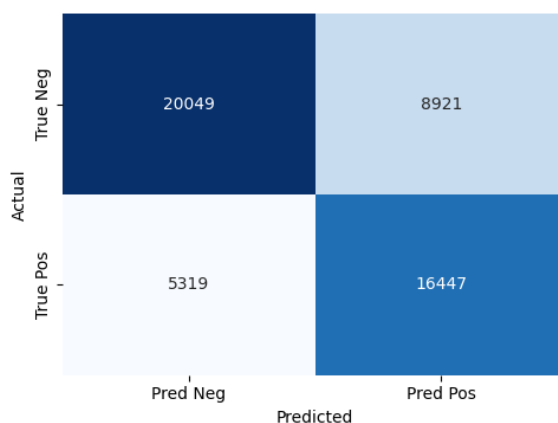
Hasil Test Penelitian

Tabel 2. Hasil Metrik Evaluasi.

Resamplers	Accuracy	Precision	Recall	F1	AUC
Tanpa Borderline SMOTE	0,731	0,706	0,638	0,670	0,802
Dengan Borderline SMOTE	0,719	0,648	0,756	0,698	0,800


Hasil pengujian akhir pada 20% data uji (*test set*) yang independen menunjukkan bahwa model Logistic Regression yang dioptimalkan dengan Borderline-SMOTE berhasil mencapai performa yang stabil dan selaras dengan tujuan penelitian. Fokus utama pada metrik Recall (Sensitivitas) menunjukkan hasil yang tinggi. Mengonfirmasikan kemampuan model dalam

mengidentifikasi sebagian besar individu dengan risiko hipertensi secara akurat. Capaian skor *recall* ini sangat krusial karena meminimalkan angka *false negative*, sehingga mengurangi risiko adanya penderita hipertensi yang tidak terdeteksi dalam proses skrining awal. Meskipun terdapat kompromi berupa skor spesifisitas yang lebih rendah, hal ini tetap dianggap rasional secara klinis untuk memastikan efektivitas deteksi dini pada populasi besar. Selain itu, nilai AUC (*Area Under the Curve*) yang konsisten dengan tahap validasi menunjukkan bahwa model memiliki kemampuan diskriminasi yang baik dan tidak mengalami *overfitting*, sehingga memberikan dasar yang kuat bagi SHAP untuk menjelaskan faktor risiko secara transparan dan terpercaya pada tingkat individu.



Gambar 2. Confusion Matrix.

Hasil *Confusion Matrix* menunjukkan bahwa model berhasil mencapai target utama penelitian dengan menempatkan mayoritas data penderita hipertensi pada kategori True Positive yang secara langsung berkontribusi pada tingginya nilai Recall. Dominasi prediksi pada kelas positif ini membuktikan bahwa implementasi *Borderline-SMOTE* efektif dalam memperkuat kemampuan model untuk mengenali pasien berisiko di area perbatasan kelas yang sebelumnya sulit dideteksi. Meskipun terdapat sejumlah sampel yang terklasifikasi sebagai False Positive sebagai kompromi medis yang rasional demi menekan angka False Negative rendahnya jumlah penderita yang terlewat (pasien yang salah didiagnosis sebagai sehat) memberikan justifikasi klinis yang kuat bahwa model ini sangat andal untuk prosedur skrining. Secara keseluruhan, distribusi hasil pada *Confusion Matrix* ini mencerminkan keseimbangan performa yang stabil, di mana model tidak hanya unggul dalam sensitivitas tetapi juga tetap mampu mempertahankan akurasi prediksi yang dapat dipertanggungjawabkan pada data uji yang independen.




Gambar 3. ROC Curve.

Hasil rata-rata pada fase pelatihan dan validasi menunjukkan nilai metrik yang identik dengan *Accuracy* 0,716, *Recall* 0,751, dan *AUC* 0,795 yang mengindikasikan bahwa model memiliki stabilitas yang sangat baik dan bebas dari gejala *overfitting*. Pada pengujian akhir menggunakan data uji independen, performa model meningkat secara konsisten dengan skor *Accuracy* 0,719, *Recall* 0,756, dan *AUC* 0,800. Tingginya nilai *Recall* (0,756) didukung oleh data *confusion matrix* yang menunjukkan model berhasil mengidentifikasi 16.447 sampel True Positive yang secara klinis membuktikan efektivitas metode Borderline-SMOTE dalam meminimalkan angka penderita hipertensi yang tidak terdeteksi (*false negative*). Meskipun terdapat 8.921 *false positive*, kompromi ini sejalan dengan tujuan penelitian untuk memprioritaskan sensitivitas dalam skrining kesehatan. Kualitas diskriminasi model dipertegas oleh kurva ROC-AUC yang mencapai angka 0,80, menunjukkan kemampuan model yang kuat dalam membedakan antara individu sehat dan penderita hipertensi, sehingga memberikan dasar yang solid untuk interpretasi fitur lebih lanjut menggunakan SHAP.

Interpretasi Model


Feature Importance



Gambar 4. Feature Importance.

Interpretasi menggunakan SHAP Feature Importance menunjukkan bahwa variabel Age (Usia) merupakan prediktor paling dominan yang memengaruhi output model, diikuti oleh HighChol (Kolesterol Tinggi), GenHlth (Kesehatan Umum), dan BMI. Hal ini mengonfirmasi secara klinis bahwa faktor demografi dan kondisi metabolik memiliki kontribusi terbesar terhadap probabilitas risiko hipertensi pada dataset BRFSS. Fitur-fitur lain seperti Sex, Diabetes, dan Heart Disease juga menunjukkan pengaruh yang signifikan, meskipun dengan besaran nilai SHAP yang lebih rendah dibandingkan empat variabel utama. Dengan mengidentifikasi peringkat pengaruh variabel ini, SHAP berhasil memberikan transparansi terhadap mekanisme internal *Logistic Regression*, sehingga praktisi kesehatan dapat memahami faktor risiko mana yang paling krusial dalam mendasari setiap prediksi model secara terukur.

Summary Plot

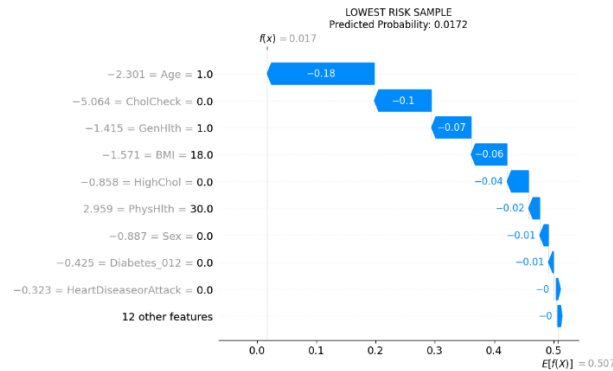


Gambar 5. Summary Plot.

SHAP Summary Plot memberikan gambaran komprehensif mengenai distribusi pengaruh fitur terhadap prediksi model, di mana nilai fitur yang tinggi (berwarna merah) pada variabel Age, BMI, dan GenHlth berkorelasi positif dengan peningkatan risiko hipertensi (nilai SHAP positif). Sebaliknya, pada variabel Age dan BMI, terlihat sebaran titik biru (nilai rendah) yang berada di area negatif, menunjukkan bahwa usia muda dan indeks massa tubuh yang rendah berperan sebagai faktor pelindung yang menurunkan probabilitas hipertensi. Variabel kategorikal seperti HighChol, Sex, dan Diabetes juga menunjukkan pola yang jelas, di mana

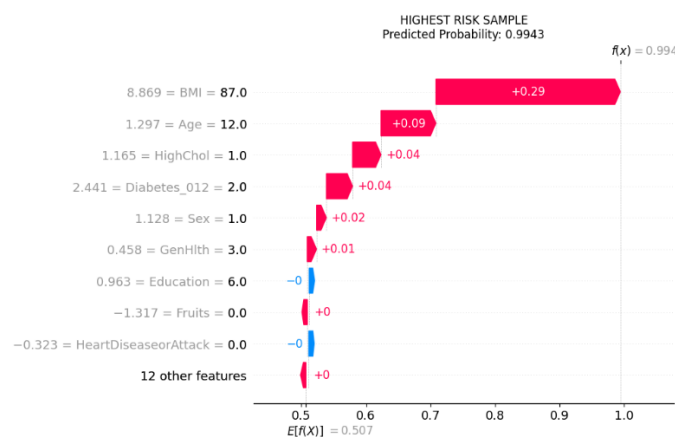
keberadaan kondisi tersebut (titik merah) secara konsisten mendorong prediksi model ke arah kelas positif. Melalui visualisasi ini, model tidak hanya terbukti memiliki performa statistik yang baik, tetapi juga memiliki konsistensi klinis di mana faktor risiko konvensional secara nyata terbukti meningkatkan skor prediksi hipertensi pada tingkat individu.

Waterfall Plot



Gambar 6. Waterfall Plot Probabilitas Prediksi Terendah.

Visualisasi ini menunjukkan bagaimana berbagai fitur secara kolektif menurunkan ekspektasi dasar model yaitu 0,507 menuju nilai probabilitas yang sangat rendah. Penurunan risiko yang paling signifikan didorong oleh variabel Age (Usia) dengan nilai kontribusi -0,18, diikuti oleh CholCheck (Pemeriksaan Kolesterol) sebesar -0,1, dan GenHlth (Kesehatan Umum) sebesar -0,07. Selain itu, faktor fisik seperti BMI yang rendah 18,0 dan absennya kondisi medis seperti HighChol serta Diabetes turut memberikan kontribusi negatif terhadap risiko hipertensi. Secara klinis, hasil ini merepresentasikan profil individu yang sangat sehat berusia muda, memiliki berat badan ideal, serta rutin melakukan pengecekan Kesehatan sehingga model secara transparan mampu mengidentifikasi bahwa individu tersebut memiliki kemungkinan terkecil untuk menderita hipertensi dibandingkan rata-rata populasi dalam dataset.



Gambar 7. Waterfall Plot Probabilitas Prediksi Tertinggi.

Visualisasi ini menunjukkan bagaimana berbagai faktor risiko secara akumulatif mendorong prediksi dari nilai ekspektasi dasar yaitu 0,507 menuju probabilitas hampir mutlak. Peningkatan risiko yang paling dominan dipicu oleh variabel BMI dengan nilai kontribusi sebesar +0,29 pada indeks massa tubuh yang sangat tinggi yaitu 87,0. Kontribusi positif selanjutnya diikuti oleh faktor Age (Usia) sebesar +0,09, serta keberadaan kondisi medis penyerta seperti HighChol (Kolesterol Tinggi) sebesar +0,04 dan Diabetes sebesar +0,04. Selain itu, variabel Sex dan GenHlth turut memberikan dorongan tambahan terhadap risiko hipertensi. Secara klinis, profil ini merepresentasikan individu dengan obesitas ekstrem dan multipatologi, di mana interaksi antar faktor risiko tersebut secara transparan menjelaskan mengapa model menetapkan tingkat probabilitas hipertensi yang sangat tinggi pada sampel tersebut.

5. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa penerapan algoritma Logistic Regression yang dioptimalkan dengan Borderline-SMOTE efektif mengatasi ketidakseimbangan data pada prediksi hipertensi, khususnya dengan meningkatkan sensitivitas sebagai prioritas klinis yang ditunjukkan oleh performa model yang stabil dengan nilai recall 0,756, akurasi 0,719, dan AUC 0,800, sehingga mampu meminimalkan risiko false negative. Integrasi metode SHAP berhasil memberikan transparansi dan akuntabilitas model dengan mengidentifikasi usia, kolesterol tinggi, dan BMI sebagai faktor paling berpengaruh secara global serta menjelaskan risiko individu pada rentang probabilitas 1,72% hingga 99,43%. Meskipun demikian, penelitian ini memiliki keterbatasan berupa penggunaan data BRFSS yang bersifat self-reported dan kompleksitas komputasi SHAP pada jumlah fitur besar, sehingga penelitian selanjutnya disarankan menggunakan data klinis riil, mengeksplorasi algoritma atau teknik penyeimbangan data yang lebih lanjut, serta memanfaatkan model ini sebagai alat pendukung pengambilan keputusan bagi instansi kesehatan dalam memetakan prioritas intervensi berbasis risiko yang transparan.

DAFTAR REFERENSI

- Aiosa, G. V., Palesi, M., & Sapuppo, F. (2023). EXplainable AI for Decision Support to Obesity Comorbidities Diagnosis. *IEEE Access*, *11*, 107767–107782. <https://doi.org/10.1109/access.2023.3320057>
- AlKaabi, L. A., Ahmed, L. S., Al Attiyah, M. F., & Abdel-Rahman, M. E. (2020). Predicting hypertension using machine learning: Findings from Qatar Biobank Study. *PLOS ONE*, *15*(10), e0240370. <https://doi.org/10.1371/journal.pone.0240370>
- Badriyah, Chamidy, T., & Suhartono. (2025). Application of SMOTE in Sentiment Analysis of MyXL User Reviews on Google Play Store. *JISKA (Jurnal Informatika Sunan Kalijaga)*, *10*(1), 74–86. <https://doi.org/10.14421/jiska.2025.10.1.74-86>
- Bifarin, O. O. (2023). Interpretable machine learning with tree-based shapley additive explanations: Application to metabolomics datasets for binary classification. *PLOS ONE*, *18*(5), e0284315. <https://doi.org/10.1371/journal.pone.0284315>
- Bisong, E., Jibril, N., Premnath, P., Buligwa, E., Oboh, G., & Chukwuma, A. (2024). Predicting high blood pressure using machine learning models in low- and middle-income countries. *BMC Medical Informatics and Decision Making*, *24*(1), 234. <https://doi.org/10.1186/s12911-024-02634-9>
- Bradshaw, T. J., Huemann, Z., Hu, J., & Rahmim, A. (2023). A Guide to Cross-Validation for Artificial Intelligence in Medical Imaging. *Radiology: Artificial Intelligence*, *5*(4), e220232. <https://doi.org/10.1148/ryai.220232>
- Chen, N., Fan, F., Geng, J., Yang, Y., Gao, Y., Jin, H., Chu, Q., Yu, D., Wang, Z., & Shi, J. (2022). Evaluating the risk of hypertension in residents in primary care in Shanghai, China with machine learning algorithms. *Frontiers in Public Health*, *10*, 984621. <https://doi.org/10.3389/fpubh.2022.984621>
- Di Franco, G., & Santurro, M. (2021). Machine learning, artificial neural networks and social research. *Quality & Quantity*, *55*(3), 1007–1025. <https://doi.org/10.1007/s11135-020-01037-y>
- Han, J., & Kamber, M. (2012). *Data mining: Concepts and techniques* (3rd ed). Elsevier.
- Hashimoto-Roth, E., Surendra, A., Lavallée-Adam, M., Bennett, S. A. L., & Čuperlović-Culf, M. (2022). METAbolomics data Balancing with Over-sampling Algorithms (META-BOA): An online resource for addressing class imbalance. *Bioinformatics*, *38*(23), 5326–5327. <https://doi.org/10.1093/bioinformatics/btac649>
- Jr, D. W. H., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression*. John Wiley & Sons.
- Khan, H., Javaid, N., Bashir, T., Akbar, M., Alrajeh, N., & Aslam, S. (2024). Heart Disease Prediction Using Novel Ensemble and Blending Based Cardiovascular Disease Detection Networks: EnsCVDD-Net and BICVDD-Net. *IEEE Access*, *12*, 109230–109254. <https://doi.org/10.1109/ACCESS.2024.3421241>
- Kumari, J., Kumar, E., & Kumar, D. (2023). A Structured Analysis to study the Role of Machine Learning and Deep Learning in The Healthcare Sector with Big Data Analytics. *Archives of Computational Methods in Engineering*, *30*(6), 3673–3701. <https://doi.org/10.1007/s11831-023-09915-y>
- Layton, A. T. (2024). AI, Machine Learning, and ChatGPT in Hypertension. *Hypertension*, *81*(4), 709–716. <https://doi.org/10.1161/HYPERTENSIONAHA.124.19468>

- Liang, B., Tong, C., Nong, J., & Zhang, Y. (2024). Histological Subtype Classification of Non-Small Cell Lung Cancer with Radiomics and 3D Convolutional Neural Networks. *Journal of Imaging Informatics in Medicine*, 37(6), 2895–2909. <https://doi.org/10.1007/s10278-024-01152-4>
- Martinez-Ríos, E., Montesinos, L., Alfaro-Ponce, M., & Pecchia, L. (2021). A review of machine learning in hypertension detection and blood pressure estimation based on clinical and physiological data. *Biomedical Signal Processing and Control*, 68, 102813. <https://doi.org/10.1016/j.bspc.2021.102813>
- Mashuri, Y. A., Ng, N., & Santosa, A. (2022). Socioeconomic disparities in the burden of hypertension among Indonesian adults—A multilevel analysis. *Global Health Action*, 15(1). <https://doi.org/10.1080/16549716.2022.2129131>
- Montagna, S., Pengo, M. F., Ferretti, S., Borghi, C., Ferri, C., Grassi, G., Muiesan, M. L., & Parati, G. (2022). Machine Learning in Hypertension Detection: A Study on World Hypertension Day Data. *Journal of Medical Systems*, 47(1). <https://doi.org/10.1007/s10916-022-01900-5>
- Ridley, M. (2022). Explainable Artificial Intelligence (XAI): Adoption and Advocacy. *Information Technology and Libraries*, 41(2). <https://doi.org/10.6017/ital.v41i2.14683>
- Salih, A., Raisi-Estabragh, Z., Galazzo, I. B., Radeva, P., Petersen, S. E., Menegaz, G., & Lekadir, K. (2023). *A Perspective on Explainable Artificial Intelligence Methods: SHAP and LIME*. <https://doi.org/10.48550/ARXIV.2305.02012>
- Sellén Crombet, Joaquín. (2008). *Hipertensión arterial: Diagnóstico, tratamiento y control*. Editorial Universitaria.
- Si, F., Liu, Q., & Yu, J. (2025). A prediction study on the occurrence risk of heart disease in older hypertensive patients based on machine learning. *BMC Geriatrics*, 25(1), 27. <https://doi.org/10.1186/s12877-025-05679-1>
- Sovia, N. A., Wardhani, N. W. S., & Sumarminingsih, E. (2024). Hybrid CNN-SVM with Borderline SMOTE for Imbalance Class Cabbage Plants. *Inferensi*, 7(3), 199. <https://doi.org/10.12962/j27213862.v7i3.20514>
- Touyz, R. M. (2022). *Hypertension 2022 Update: Focusing on the Future*. *Hypertension*, 79(8), 1559–1562. <https://doi.org/10.1161/HYPERTENSIONAHA.122.19564>
- Trevisan, P., Pasquato, M., Carenini, G., Mekhaël, N., Braga, V. F., Bono, G., & Abbas, M. (2023). Sparse Logistic Regression for RR Lyrae versus Binaries Classification. *The Astrophysical Journal*, 950(2), 103. <https://doi.org/10.3847/1538-4357/accf8f>
- Vera, J. F. (2022). Distance-based logistic model for cross-classified categorical data. *British Journal of Mathematical and Statistical Psychology*, 75(3), 466–492. <https://doi.org/10.1111/bmsp.12264>
- Weir, M. R. (2010). *Evidence-based management of hypertension* (First edition). tfm Pub.