

Smart Health Monitoring Berbasis Machine Learning untuk Prediksi Risiko Stroke sebagai Upaya Pencegahan Dini Kesehatan Masyarakat

Machine Learning-Based Smart Health Monitoring for Stroke Risk Prediction as an Early Prevention Effort for Public Health

Mundirin^{*1}, Idawati², Deden Hedin Purnama³, Anas Nasrullah⁴ (* correspondent author)

^{1,2,3}Sistem Informasi/Institut Sains dan Teknologi Al-Kamal

E-mail: ¹mundirin.imung@gmail.com, ²idawati.ista76@gmail.com,

³purnama95@gmail.com, ⁴anasnasroellah@gmail.com

Abstrak

Stroke merupakan salah satu penyebab utama kematian dan kecacatan di Indonesia, dengan prevalensi yang terus meningkat termasuk pada usia produktif. Metode skrining stroke yang saat ini masih dilakukan secara manual dan subjektif belum mampu mengidentifikasi pola risiko kompleks dalam data klinis dan gaya hidup pasien. Penelitian ini mengembangkan sistem Smart Health Monitoring berbasis machine learning yang terintegrasi dengan dashboard klinik digital untuk mendukung deteksi dini risiko stroke di fasilitas kesehatan primer, menggunakan dataset Healthcare Stroke Data (Kaggle, 2023) dengan 5.110 rekam medis pasien. Tiga algoritma dibandingkan secara sistematis: Random Forest, XGBoost, dan Stacked Ensemble (Random Forest dan XGBoost sebagai base learner dengan Logistic Regression sebagai meta-learner). Ketidakseimbangan kelas yang ekstrem (95,1% berbanding 4,9%) ditangani menggunakan SMOTE berbasis k-Nearest Neighbors (k=5) yang diterapkan secara leak-free pada setiap fold cross-validation. Evaluasi dilakukan menggunakan Akurasi, Sensitivitas, Spesifisitas, F1-Score, dan AUC-ROC. Hasil menunjukkan XGBoost menghasilkan AUC-ROC tertinggi (79,23%) dengan Spesifisitas 99,69%, sementara Random Forest memberikan Sensitivitas terbaik (22,00%) dengan AUC-ROC 78,74%; Stacked Ensemble menghasilkan keseimbangan performa (AUC-ROC 78,93%). Interpretabilitas model dikaji menggunakan Explainable AI melalui analisis SHAP values yang mengidentifikasi usia, rata-rata glukosa darah, dan BMI sebagai tiga fitur paling berpengaruh. Penelitian ini dilengkapi dengan prototype dashboard klinik digital berbasis Streamlit dengan fitur prediksi risiko secara berkelanjutan.

Kata kunci: stroke; machine learning; Random Forest; XGBoost; SHAP;

Abstract

Stroke is a leading cause of death and disability in Indonesia, with a rising prevalence that extends to the working-age population. Current stroke screening methods which remain largely manual and subjective fail to identify complex risk patterns within patient clinical and lifestyle data. This study develops a machine learning-based Smart Health Monitoring system integrated with a digital clinical dashboard to support early stroke risk detection in primary healthcare facilities, utilizing the Healthcare Stroke Data dataset (Kaggle, 2023) comprising 5,110 patient records. Three algorithms were systematically compared: Random Forest, XGBoost, and a Stacked Ensemble (using Random Forest and XGBoost as base learners and Logistic Regression as the meta-learner). Extreme class imbalance (95.1% vs. 4.9%) was addressed using k-Nearest Neighbors (k=5)-based SMOTE, applied in a leak-free manner across each cross-validation fold. Evaluation metrics included Accuracy, Sensitivity, Specificity, F1-Score, and AUC-ROC. Results indicate that XGBoost achieved the highest AUC-ROC (79.23%) with 99.69% Specificity, while Random Forest yielded the best Sensitivity

(22.00%) with an AUC-ROC of 78.74%; the Stacked Ensemble provided a balanced performance (AUC-ROC 78.93%). Model interpretability was assessed via Explainable AI using SHAP value analysis, identifying age, average blood glucose, and BMI as the three most influential features. The study concludes with the development of a Streamlit-based digital clinical dashboard prototype featuring continuous risk prediction capabilities.

Keywords: stroke; machine learning; Random Forest; XGBoost; SHAP;

1. PENDAHULUAN

Stroke adalah gangguan fungsi otak yang berkembang cepat akibat gangguan vaskular, baik karena penyumbatan pembuluh darah (*stroke iskemik*, $\pm 87\%$ kasus) maupun pecahnya pembuluh darah (*stroke hemoragik*). Berdasarkan data *World Health Organization (WHO)*, stroke merupakan salah satu penyebab kematian tertinggi di dunia; setiap tahun sekitar 15 juta orang mengalami stroke, dengan 5 juta di antaranya meninggal dunia dan 5 juta lainnya mengalami kecacatan permanen [1].

Di Indonesia, Riset Kesehatan Dasar (Riskesdas) 2023 mencatat prevalensi stroke mencapai 10,9 per 1.000 penduduk, dengan tren kasus yang semakin banyak terjadi pada usia produktif (di bawah 45 tahun). Faktor risiko utama yang dapat dimodifikasi meliputi hipertensi (kontributor terbesar, 35–50% kasus), diabetes mellitus, penyakit jantung, obesitas, dan merokok, dengan kombinasi beberapa faktor risiko meningkatkan risiko secara multiplikatif [1].

Salah satu tantangan utama dalam pencegahan stroke adalah keterbatasan *skrining* di fasilitas kesehatan primer, yang umumnya masih dilakukan secara manual dan sangat bergantung pada penilaian subjektif tenaga medis, sehingga belum mampu mengidentifikasi pola kompleks antar faktor risiko yang tersimpan dalam data klinis pasien.

Dalam beberapa tahun terakhir, *Machine Learning (ML)* menunjukkan hasil yang menjanjikan dalam memprediksi risiko stroke melalui algoritma seperti *Random Forest*, *XGBoost*, dan *Stacked Ensemble* [2][3][4][5]. Kemajuan *Explainable AI (XAI)* turut memungkinkan model memberikan penjelasan yang transparan kepada klinisi terkait kontribusi tiap faktor risiko terhadap hasil prediksi [6][7][8][9]. Meskipun demikian, sebagian besar penelitian masih terpusat pada pembangunan model prediksi tanpa mengintegrasikannya ke dalam sistem klinis yang siap digunakan secara langsung di fasilitas kesehatan primer [11][12][13].

Berangkat dari kesenjangan tersebut, penelitian ini mengembangkan sistem *Smart Health Monitoring* berbasis *machine learning* yang membandingkan tiga algoritma klasifikasi yaitu *Random Forest*, *XGBoost*, dan *Stacked Ensemble*, menggunakan dataset *Healthcare Stroke Data* yang mencakup 5.110 rekam medis pasien dengan 10 variabel klinis dan demografis. Inovasi utama penelitian ini meliputi: (1) penerapan *SMOTE* berbasis *k-NN* yang *leak-free* untuk menangani ketidakseimbangan kelas ekstrem (95,1% vs 4,9%); (2) implementasi *Explainable AI* menggunakan *SHAP values* untuk interpretabilitas klinis; serta (3) integrasi model ke dalam dashboard klinik digital berbasis Streamlit sebagai wujud nyata

Smart Health Monitoring yang diharapkan mampu memfasilitasi kesehatan primer [14][15][16][17].

2. METODOLOGI PENELITIAN


Penelitian ini merupakan penelitian terapan (*applied research*) berbasis eksperimen komputasional dengan pendekatan kuantitatif dan prediktif. Metode yang digunakan adalah studi komparatif (*comparative study*) untuk membandingkan performa tiga algoritma machine learning yaitu : *Random Forest*, *XGBoost*, dan *Stacked Ensemble*, dalam tugas klasifikasi biner prediksi risiko stroke, dilengkapi dengan implementasi *Explainable AI* dan dashboard klinik digital. Dataset yang digunakan adalah *Healthcare Stroke Data* yang tersedia secara publik di platform Kaggle [14] (<https://www.kaggle.com/datasets/fedesoriano/stroke-prediction-dataset>). Dataset ini terdiri dari 5.110 rekam medis pasien dengan 12 variabel (11 fitur prediktor + 1 variabel target).

Tabel 2.1 Deskripsi Variabel Dataset Healthcare Stroke Data

Variabel	Tipe	Deskripsi
id	Integer	Identifikasi unik pasien (dihapus saat preprocessing)
gender	Kategorikal	Jenis kelamin (Male/Female/Other)
age	Numerik	Usia pasien dalam tahun (0,08–82)
hypertension	Biner	Riwayat hipertensi (0=Tidak, 1=Ya)
heart_disease	Biner	Riwayat penyakit jantung (0=Tidak, 1=Ya)
ever_married	Kategorikal	Status pernikahan (Yes/No)
work_type	Kategorikal	Jenis pekerjaan (5 kategori)
Residence_type	Kategorikal	Jenis tempat tinggal (Urban/Rural)
avg_glucose_level	Numerik	Rata-rata kadar glukosa darah (mg/dL)
bmi	Numerik	Body Mass Index; 201 nilai hilang (3,9%)
smoking_status	Kategorikal	Status merokok (4 kategori)
stroke (Target)	Biner	1=Stroke (249 kasus, 4,87%), 0=Tidak Stroke (4.860 kasus, 95,13%)

2.1. Alur Penelitian

Alur penelitian terdiri dari lima tahap utama: (1) pengumpulan dan pemahaman data; (2) preprocessing data; (3) pembangunan dan pelatihan model; (4) evaluasi model beserta interpretasi *Explainable AI*; serta (5) implementasi sistem dan pengembangan dashboard klinik digital.



Gambar 2. Alur Penelitian

2.1.1 Tahap Preprocessing

- a) *Pembersihan Data (Data Cleaning)*
Pembersihan Data (Data Cleaning). Tahap ini meliputi: (1) penghapusan kolom id yang tidak memiliki nilai prediktif; dan (2) penghapusan 1 baris dengan *gender='Other'* karena tidak representatif secara statistik. Setelah pembersihan, dataset terdiri dari 5.109 baris.
- b) *Pembagian Data (Train/Test Split)*
Pembagian data menjadi set *training* (80%) dan *testing* (20%) dilakukan sebelum tahap imputasi dan *SMOTE* untuk mencegah data *leakage*. *Stratified split* digunakan untuk memastikan proporsi kelas target tetap terjaga di kedua set. Hasilnya: 4.087 sampel untuk training dan 1.022 sampel untuk testing
- c) *Imputasi Nilai Hilang*
Variabel *BMI* memiliki 201 nilai hilang (3,9%). Imputasi dilakukan menggunakan median *BMI* per kelompok usia, karena *BMI* berkorelasi signifikan dengan usia dan distribusinya berbeda antar kelompok umur. Median dihitung dari data *training* dan diterapkan ke data testing untuk mencegah information leakage. Lima kelompok usia yang digunakan: <18 tahun, 18-35 tahun, 35-50 tahun, 50-65 tahun, dan >65 tahun
- d) *Encoding Variabel Kategorikal*.
Lima variabel kategorikal (*gender*, *ever_married*, *work_type*, *Residence_type*, *smoking_status*) dikonversi menjadi nilai numerik menggunakan pemetaan eksplisit berbasis *category_map*. Pendekatan ini dipilih dibandingkan *LabelEncoder* sklearn standar karena lebih *robust* terhadap kategori yang tidak dikenal saat fase *deployment* nilai yang tidak dikenal akan dipetakan ke nilai *default* (0) alih-alih menimbulkan *error*.
- e) *Penanganan Ketidakseimbangan Kelas (SMOTE-K-NN)*
Ketidakseimbangan kelas yang ekstrem (95,1% vs 4,9%) ditangani menggunakan *SMOTE* berbasis k-Nearest Neighbors (*k=5*). Implementasi yang dikembangkan dalam penelitian ini secara teknis benar sesuai algoritma *SMOTE* original: untuk setiap sampel sintetis, dipilih satu sampel minoritas secara acak, dicari k tetangga terdekatnya di kelas minoritas, dipilih satu tetangga secara acak, lalu dilakukan *interpolasi linear* antara keduanya. *SMOTE* hanya diterapkan pada data training, dan diterapkan ulang pada setiap fold dalam *cross-validation* untuk menghindari data *leakage*. Setelah *SMOTE*, distribusi kelas menjadi seimbang (3.888 vs 3.888).
- f) *Feature Scaling*

Normalisasi fitur menggunakan *StandardScaler* (mean=0, std=1) dilakukan di dalam *sklearn Pipeline*, bukan sebagai langkah terpisah. Hal ini memastikan bahwa *scaler* hanya di-fit pada data *training* dan diterapkan secara konsisten saat *inference*, tanpa risiko kebocoran statistik dari data testing.

2.1. 2 Konfigurasi Model

- a) *Random Forest*. Dibangun dengan 200 pohon keputusan ($n_estimators=200$), kedalaman maksimum 8 ($max_depth=8$), dan $class_weight='balanced'$ untuk memberi bobot lebih pada kelas minoritas.
- b) *XGBoost*. Diimplementasikan menggunakan *Gradient Boosting* dengan konfigurasi $n_estimators=200$, $learning_rate=0,05$, dan $max_depth=4$, dipilih untuk menyeimbangkan performa dan kemampuan generalisasi serta mengurangi risiko *overfitting* pada kelas mayoritas.
- c) *Stacked Ensemble*. Dibangun menggunakan *StackingClassifier* dengan dua base learner (*Random Forest* dan *XGBoost*) dan *Logistic Regression* ($class_weight='balanced'$) sebagai *meta-learner*. *Cross-validation 5-fold* digunakan untuk menghasilkan *out-of-fold predictions* sebagai input *meta-learner*, guna mencegah kebocoran informasi dari *base learner* ke *meta-learner*.

Seluruh model dibungkus dalam *sklearn.Pipeline* yang mengenkapsulasi *StandardScaler* dan algoritma klasifikasi secara berurutan, sehingga aman untuk *deployment* tanpa risiko langkah transformasi yang terlewat.

2.1. 3 Implementasi Explainable AI (SHAP)

SHAP (*SHapley Additive exPlanations*) diterapkan pada model dengan performa terbaik untuk menghitung kontribusi setiap fitur terhadap prediksi individual berdasarkan teori permainan kooperatif (*Shapley values*). Visualisasi SHAP yang digunakan mencakup: (1) *SHAP summary plot* untuk menampilkan fitur paling berpengaruh secara global; (2) *SHAP bar plot* untuk perbandingan *mean absolute SHAP values* antar fitur; dan (3) *SHAP force plot* untuk menjelaskan prediksi individual per pasien [1][3][20].

2.1. 4 Evaluasi Model

Evaluasi dilakukan pada dua tingkatan: (1) evaluasi pada test set (1.022 sampel) yang tidak pernah digunakan selama training maupun validasi; dan (2) 5-fold *stratified cross-validation* yang diterapkan secara leak-free (*SMOTE* diterapkan ulang di dalam setiap fold pada data original sebelum *SMOTE global*). Metrik evaluasi yang digunakan meliputi Akurasi, *Sensitivitas (Recall)*, *Spesifisitas*, *F1-Score*, dan *AUC-ROC* sesuai relevansi klinisnya masing-masing dalam konteks skrining risiko stroke [15]. Model terbaik dipilih berdasarkan *AUC-ROC* tertinggi pada test set, karena metrik ini paling merepresentasikan kemampuan diskriminasi model secara keseluruhan pada data dengan ketidakseimbangan kelas ekstrem.

2.1. 5 Implementasi Sistem

Model terbaik beserta seluruh komponen *preprocessing* (*category_map*, *feature_cols*, *Pipeline*) disimpan dalam format .pkl menggunakan joblib. Dashboard klinik digital dibangun menggunakan Streamlit dengan empat modul utama: (1) Dashboard ringkasan statistik dataset; (2) *Eksplorasi Data (EDA)* interaktif; (3) Perbandingan Model dan visualisasi *ROC curve*; serta (4) Prediksi Risiko Pasien Baru secara *real-time* disertai visualisasi gauge risiko, identifikasi faktor risiko individual, dan rekomendasi tindakan. Penggunaan *sklearn.Pipeline* memastikan input pengguna melewati urutan transformasi yang identik dengan proses training [18][24][25].

3. HASIL DAN PEMBAHASAN

3.1 Hasil *Preprocessing*

a) Analisis Deskriptif *Dataset*

Dataset awal terdiri dari 5.110 sampel dengan 12 variabel. Setelah pembersihan data (penghapusan kolom id dan 1 baris dengan *gender='Other'*), dataset menjadi 5.109 sampel dengan 10 *fitur prediktor*. Variabel BMI memiliki 201 nilai hilang (3,9%) yang diimputasi dengan median per kelompok usia. Distribusi target sangat tidak seimbang: 4.861 sampel tidak stroke (95,1%) dan 249 sampel stroke (4,9%).

b) Analisis Faktor Risiko

Analisis bivariat menunjukkan pola yang konsisten dengan literatur medis. Usia menjadi prediktor terkuat: rata-rata usia pasien stroke adalah 68,5 tahun dibandingkan 41,9 tahun untuk non-stroke. Tabel 2 merangkum stroke rate per faktor risiko utama.

Tabel 2. Stroke Rate per Faktor Risiko Utama

Faktor Risiko	Stroke Rate (%)	Tingkat Risiko
Kombinasi Hipertensi + Penyakit Jantung	20,3	Sangat Tinggi
Penyakit Jantung	17,0	Sangat Tinggi
Usia $\geq$ 65 tahun	16,2	Tinggi
Hipertensi	13,3	Tinggi
Glukosa > 200 mg/dL	12,9	Tinggi
Pernah Merokok	7,9	Sedang
Aktif Merokok	5,3	Sedang
Baseline (seluruh pasien)	4,87	—

Sumber: Hasil analisis dataset Healthcare Stroke Data [30]

c) Hasil Penyeimbangan Data

Setelah penerapan *SMOTE k-NN* ($k=5$) pada data training, distribusi kelas menjadi seimbang dengan 3.888 sampel untuk masing-masing kelas (total 7.776 sampel training). *SMOTE* diterapkan ulang secara independen pada setiap fold dalam *cross-validation*, sehingga data validasi pada setiap fold

tetap mencerminkan distribusi kelas yang asli (*imbalanced*) memberikan estimasi performa yang realistis terhadap data nyata.

3.2 Hasil *Training* dan Evaluasi Model

Tabel 3 menyajikan hasil evaluasi komprehensif ketiga model pada test set (1.022 sampel) yang tidak pernah digunakan selama proses *training* maupun validasi.

Tabel 3. Perbandingan Performa Model pada Test Set

Model	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)	F1 (%)	AUC-ROC (%)
Random Forest	93,25	22,00	96,91	17,39	78,74
XGBoost	95,21	8,00	99,69	11,43	79,23
Stacked Ensemble	94,42	8,00	98,87	10,53	78,93

Keterangan: Nilai terbaik per metrik dicetak tebal. XGBoost terpilih sebagai model terbaik berdasarkan AUC-ROC tertinggi

Confusion matrix ketiga model pada test set (n=1.022) disajikan pada Tabel 4 untuk memberikan gambaran detail distribusi prediksi benar dan salah pada masing-masing kelas.

Tabel 4. Confusion Matrix Ketiga Model (Test Set, n=1.022)

Model	TP (Stroke Terdeteksi)	TN (Non-Stroke Benar)	FP (Alarm Palsu)	FN (Stroke Terlewat)
Random Forest	11	941	30	39
XGBoost	4	971	3	46
Stacked Ensemble	4	958	11	46

Keterangan: TP=True Positive, TN=True Negative, FP=False Positive, FN=False Negative

3.3 Hasil *Implementasi Explainable AI*

Analisis *SHAP* diterapkan pada model *XGBoost* (model dengan *AUC-ROC* tertinggi) untuk mengidentifikasi kontribusi setiap fitur terhadap prediksi risiko stroke. *SHAP summary plot* menunjukkan bahwa usia (*age*) memiliki *mean absolute SHAP value* tertinggi, mengonfirmasi perannya sebagai prediktor dominan, diikuti oleh rata-rata glukosa darah (*avg_glucose_level*) dan *BMI*. Pada tingkat individual, *SHAP force plot* menunjukkan bahwa untuk pasien berusia 72 tahun dengan riwayat *hipertensi* dan glukosa 220 mg/dL, faktor usia dan glukosa tinggi mendorong *probabilitas* prediksi stroke ke atas secara signifikan, sementara jenis kelamin perempuan dan status tidak merokok sedikit menurunkan risiko yang memberikan penjelasan yang transparan dan dapat dipercaya bagi tenaga kesehatan [26][27].

3.4 Pembahasan Hasil

a. Analisis *XGBoost* sebagai Model Terbaik

XGBoost terpilih sebagai model terbaik dengan *AUC-ROC* sebesar 79,23% dan *spesifisitas* 99,69%. *Spesifisitas* yang mendekati sempurna ini menjamin model sangat akurat dalam mengidentifikasi individu sehat, sehingga

mengurangi risiko alarm palsu di fasilitas kesehatan. Namun, rendahnya tingkat *sensitivitas* (8,00%) menjadi catatan kritis yang harus dipertimbangkan dalam implementasi skrining klinis [28].

b. *Trade-off Sensitivitas dan Spesifisitas*

Terdapat *trade-off inherent* antara *Sensitivitas* (kemampuan mendeteksi kasus stroke nyata) dan *Spesifisitas* (kemampuan mengidentifikasi non-stroke). Random Forest memberikan *Sensitivitas* tertinggi (22,00%) dengan *Spesifisitas* 96,91%. Dalam konteks skrining klinis, *Sensitivitas* lebih penting untuk menghindari kasus stroke yang terlewat (*false negative*), sementara *Spesifisitas* penting untuk efisiensi sistem kesehatan. *Threshold tuning* pasca-training (misalnya menurunkan *threshold* keputusan dari 0,5 menjadi 0,2–0,3) berpotensi meningkatkan *Sensitivitas* secara signifikan tanpa mengorbankan *AUC-ROC*.

c. Temuan *Explainable AI*


Identifikasi tiga fitur terpenting (usia, glukosa, *BMI*) melalui *SHAP* konsisten dengan bukti klinis dan epidemiologis yang ada, memberikan validasi tambahan bahwa model tidak hanya akurat secara statistik, tetapi juga masuk akal secara medis. *Transparansi* ini krusial bagi adopsi model ML oleh tenaga kesehatan, yang memerlukan pemahaman atas dasar prediksi sebelum digunakan dalam pengambilan keputusan klinis [29][30].

d. Keterbatasan Penelitian


Beberapa keterbatasan perlu diakui: (1) dataset bersifat sekunder dan mungkin tidak sepenuhnya merepresentasikan populasi Indonesia; (2) variabel penting seperti kadar kolesterol, fibrilasi atrium, dan riwayat TIA tidak tersedia dalam dataset; (3) validasi lapangan pada tenaga kesehatan di klinik/puskesmas belum dilaksanakan dan merupakan rencana tahap berikutnya; serta (4) implementasi *LIME* sebagai metode *XAI* komplementer belum disertakan dalam penelitian ini.

3.5 Implementasi Dashboard Klinik Digital


Dashboard klinik digital berhasil diimplementasikan menggunakan *Streamlit* dengan empat modul: (1) *Dashboard statistik*; (2) *EDA interaktif*; (3) Perbandingan Model; dan (4) Prediksi Risiko real-time. Fitur prediksi memungkinkan tenaga kesehatan memasukkan data pasien (demografis, klinis, gaya hidup) dan memperoleh estimasi probabilitas risiko stroke, disertai visualisasi gauge risiko, identifikasi faktor risiko individual, dan rekomendasi tindakan. Model *XGBoost* yang tersimpan dalam *sklearn.Pipeline* (format .pkl) digunakan sebagai engine prediksi untuk menjamin konsistensi antara hasil training dan inference.



Gambar 3.1 Tampilan Dashboard Aplikasi




Gambar 3.2 Tampilan EDA interaktif



Gambar 3.3 Tampilan Perbandingan Model

Gambar 3.4 Tampilan Prediksi input pasien baru



Gambar 3.5 Tampilan Hasil Prediksi Baru

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat ditarik kesimpulan sebagai berikut:

1. *Pipeline preprocessing* yang komprehensif dan bebas data *leakage* berhasil dikembangkan, mencakup imputasi BMI berbasis median kelompok usia, encoding kategorikal eksplisit yang robust, *SMOTE k-NN* yang diterapkan ulang pada setiap *fold cross-validation*, serta pembungkusan seluruh transformasi dalam *sklearn.Pipeline* untuk menjamin konsistensi deployment.
2. Dari tiga algoritma yang dibandingkan *Random Forest*, *XGBoost*, dan *Stacked Ensemble XGBoost* menghasilkan *AUC-ROC* tertinggi (79,23%) dan Spesifisitas terbaik (99,69%), menjadikannya model terpilih. *Random Forest* memberikan Sensitivitas terbaik (22,00%), berguna sebagai model skrining awal, sementara *Stacked Ensemble* memberikan *AUC-ROC* kompetitif (78,93%) dengan kestabilan performa.

3. Implementasi *Explainable AI* menggunakan *SHAP* values berhasil mengidentifikasi usia, rata-rata glukosa darah, dan BMI sebagai tiga faktor risiko paling berpengaruh, memberikan transparansi yang diperlukan agar model dapat diterima dan dipercaya oleh tenaga kesehatan.
4. Sistem *Smart Health Monitoring* berhasil dibangun sebagai *dashboard* klinik digital berbasis *Streamlit* dengan empat modul, menyediakan prediksi risiko stroke real-time disertai interpretasi berbasis *XAI* yang dapat digunakan di fasilitas kesehatan primer sebagai instrumen skrining awal.

Penelitian lanjutan disarankan untuk mengumpulkan dataset primer dari fasilitas kesehatan Indonesia, mengeksplorasi *threshold tuning* dan teknik penyeimbangan data alternatif, melengkapi *interpretabilitas* dengan *LIME*, serta melakukan validasi lapangan dan usability testing bersama tenaga kesehatan sebelum sistem diterapkan secara luas.

UCAPAN TERIMA KASIH

Ucapan terimakasih penulis sampaikan kepada Kementerian Pendidikan Tinggi, Sains dan Teknologi atas hibah dengan skema "Penelitian Dosen Pemula" yang diberikan dengan nomor Kontrak 282/C3/DT.05.00/PL-BARU/2026 dan ucapan terimakasih kepada Institut Sains dan Teknologi Al-Kamal yang mendukung kegiatan penelitian ini.

DAFTAR PUSTAKA

- [1] World Health Organization. Global Health Estimates: Stroke. WHO Press, 2022.
- [2] Moulaei, K. et al. Explainable artificial intelligence for stroke prediction through comparison of deep learning and machine learning models. *Scientific Reports*, 2024.
- [3] Vu, T. et al. Machine Learning Approaches for Stroke Risk Prediction. *Scientific Reports*, 2024.
- [4] Gupta, A. et al. Stroke Prediction Using Neural Networks and XGBoost. *Journal of Medical Systems*, 2025.
- [5] Chakraborty, P. et al. Predicting stroke occurrences: stacked ML approach. *BMC Bioinformatics*, 2024.
- [6] Islam, M. S. et al. Explainable AI Model for Stroke Prediction. *Sensors*, 2022.
- [7] Byna, A. et al. Critical review on predicting stroke using ML and DL. *IEEE Access*, 2024.
- [8] Tang, M. et al. Explainability in healthcare ML with SHAP and LIME. *Health Informatics Journal*, 2023.
- [9] Dubey, Y. et al. Explainable model for early stroke detection. *Diagnostics (MDPI)*, 2024.
- [10] Pratama, R. et al. Digital Health Transformation in Primary Care. *Health Systems & Reform*, 2024.
- [11] Kwon, H. et al. AI-Assisted Clinical Dashboards for Stroke. *Health Informatics Journal*, 2023.

- [12] Wang, Y. et al. Integrating ML Models into Clinical Dashboards. *Journal of Biomedical Informatics*, 2022.
- [13] Melnykova, N. et al. Machine learning for stroke prediction using imbalanced data. *Scientific Reports*, 2025.
- [14] Kaggle. Healthcare Stroke Data. 2023. Tersedia: <https://www.kaggle.com/datasets/fedesoriano/stroke-prediction-dataset>
- [15] White, A. et al. Predicting recovery following stroke: deep learning. *Neuroinformatics*, 2024.
- [16] Sahriar, S. et al. Interpretable ML methods for stroke prediction. *IEEE Transactions on Biomedical Engineering*, 2024.
- [17] Mochurad, L. et al. Improving stroke risk prediction using XGBoost and PCA. *BMC Medical Informatics and Decision Making*, 2025.
- [18] Akinwumi, P. O. et al. Evaluating Machine Learning Models for Stroke Prediction. *Frontiers in Neurology*, 2025.
- [19] Mundirin, & Adistira, M. D. Sistem Informasi Perpustakaan (SIPUSTAKA) Menggunakan Metode Rapid Application Development (RAD). *Jurnal Teknologi Informasi dan Komunikasi*, 15(2), 263–268, 2024.
- [20] Asadi, F. et al. The most efficient ML algorithms in stroke prediction. *Scientific Reports*, 2024.
- [21] Chakraborty, P. et al. Predicting stroke occurrences: stacked ML approach. *BMC Bioinformatics*, 2024.
- [22] Chung, C.-C. et al. XGBoost-based simple model for stroke outcomes. *Scientific Reports*, 2023.
- [23] Tang, Z. et al. Prediction of post-stroke walking independence. *Journal of Rehabilitation Research*, 2024.
- [24] Hassan, H. et al. Predictive modelling & risk factors for early stroke detection. *Scientific Reports*, 2024.
- [25] Chakraborty, R. et al. Stacked ML with PCA for stroke prediction. *arXiv preprint*, 2024.
- [26] Mundirin, & Prasetiana, J. The tidal station management application (PAS). *Journal of Information System, Applied, Management, Accounting and Research*, 6(1), 232–239, 2022.
- [27] Sari, D., & Putra, R. Model prediktif PTM di klinik daerah. *Jurnal Informatika Kesehatan Indonesia*, 2022.
- [28] Nguyen, M. et al. Lifestyle Features Improve Stroke Prediction Models. *Scientific Reports*, 2022.
- [29] Chen, S. et al. Random Forest for clinical risk prediction. *IEEE JBHI*, 2021.
- [30] Rajkomar, O. et al. Machine Learning in Medicine. *Nature Medicine*, 2020.