

Pengembangan Model Prediksi Penyakit Ginjal Menggunakan Algoritma *Random Forest*, *Support Vector Machine*, dan *Deep Learning* Berbasis LSTM dengan Implementasi Flask

Muhammad Al Fikri
Fakultas Ilmu Terapan
Telkom University
Kota Bandung, Indonesia
fikrialzahar@student.telkomuniversity.ac.id

Elis Hernawati
Fakultas Ilmu Terapan
Telkom University
Kota Bandung, Indonesia
elishernawati@tass.telkomuniversity.ac.id

Abstrak — Penyakit ginjal kronis (PGK) merupakan salah satu masalah kesehatan global yang serius karena sering kali tidak menimbulkan gejala pada tahap awal namun berisiko berujung pada gagal ginjal. Penelitian ini bertujuan membangun model prediksi dini PGK menggunakan tiga algoritma, yaitu Random Forest, Support Vector Machine (SVM), dan Long Short-Term Memory (LSTM), yang kemudian diimplementasikan pada sistem berbasis web dengan framework Flask. Proses pengembangan mengikuti tahapan CRISP-DM, mulai dari eksplorasi dan pembersihan data, pelatihan, evaluasi, hingga implementasi. Dataset yang digunakan berasal dari UCI dengan 26 fitur medis. Evaluasi dilakukan menggunakan akurasi, presisi, recall, dan F1-score, dengan hasil terbaik ditunjukkan oleh Random Forest yang mencapai akurasi 99,1% pada pembagian data 70:30. Sistem berbasis Flask ini dirancang agar mudah digunakan tenaga medis tanpa harus memahami aspek teknis pemrograman. Selain itu, integrasi LIME membantu meningkatkan transparansi prediksi dengan menampilkan kontribusi fitur secara visual.

Kata kunci— Penyakit Ginjal Kronis, Random Forest, SVM, LSTM, Flask

I. PENDAHULUAN

Penyakit ginjal adalah kondisi gangguan pada fungsi ginjal yang menyebabkan ketidakmampuan organ dalam menyaring limbah metabolik, menjadi keseimbangan cairan, dan mengatur tekanan darah secara optimal. Penyakit ginjal sendiri dapat dibagi menjadi beberapa kategori yaitu, penyakit acute kidney injury (AKI), acute kidney disease (AKD), dan chronic kidney disease (CKD) [1]. Acute kidney injury (AKI) adalah penurunan fungsi ginjal secara cepat dengan ditandai peningkatan kadar kreatinin atau penurunan produksi urin. Acute kidney disease (AKD) adalah kondisi gangguan ginjal yang berlangsung kurang dari 3 bulan dan tidak memenuhi kriteria AKI atau CKD dan sering kali menjadi fase transisi. Sedangkan, chronic kidney disease (CKD) adalah kondisi penurunan fungsi ginjal yang berlangsung selama 3 bulan atau lebih dengan gejala awal yang tidak terdeteksi dan berisiko menjadi gagal ginjal [1]. Kondisi kategori penurunan kondisi ginjal ini merupakan salah satu kondisi yang patut diwaspadai oleh para pasien.

Namun, salah satu kategori penyakit ginjal yang sering kali ditemui pada pasien adalah *chronic kidney disease* (CKD) atau penyakit ginjal kronis (PGK). Berdasarkan data Global Burden of Disease tahun 2010 [2], penyakit ginjal kronis menjadi penyebab kematian ke-18 tertinggi di dunia. Data ini menunjukkan adanya masalah kesehatan yang cukup serius pada penyakit ginjal kronis (PGK). Pada data Riskesdas 2018 nilai prevalensi penyakit ginjal kronis atau *chronic kidney disease* (CKD) mengalami peningkatan sebesar 1,8% [3]. Adanya temuan data ini menunjukkan *chronic kidney disease* (CKD) merupakan sebuah kondisi kesehatan yang patut diwaspadai dan dicegah secara dini melalui berbagai upaya.

Berdasarkan Global burden of Disease penyakit ginjal kronis menjadi penyebab kematian tertinggi ke-18 di dunia pada tahun 2010. Oleh karena itu, penelitian ini bertujuan membangun model prediksi menggunakan tiga algoritma yaitu Random Forest, SVM, LSTM dan diimplementasikan menggunakan flask dengan tampilan sederhana dan *user friendly*. Hal ini diperkuat dengan penelitian yang menjelaskan peran teknologi dalam bidang medis dijelaskan oleh [4], yang membahas pemanfaatan AI dalam *telemedicine* dari perspektif profesional kesehatan. Pada penelitian tersebut dijelaskan bahwa penggunaan AI, termasuk juga *machine learning* dan *deep learning*, telah menjadi pendekatan utama dalam meningkatkan efektivitas pelayanan kesehatan, terutama dalam sistem diagnosis berbasis data.

Dengan ini penelitian ini menggunakan tiga algoritma yaitu Random Forest, SVM, LSTM dan diimplementasikan menggunakan flask. Flask digunakan untuk deployment sistem prediksi dini penyakit ginjal kronis. Tujuan dari penelitian ini membangun model prediksi dini penyakit ginjal kronis dengan 3 algoritma yang ditentukan dan menggunakan model terbaik. Hasil penelitian ini berguna bagi tenaga medis untuk memberikan rekomendasi kemudahan dalam akses sistem prediksi penyakit ginjal kronis berbasis website.

II. KAJIAN TEORI

A. Penyakit Ginjal

Penyakit ginjal adalah kondisi fungsi ginjal menurun atau terganggu, karena ginjal tidak mampu menyaring limbah dan cairan tubuh secara optimal [3]. Gangguan ini

menyebabkan penumpukan zat beracun yang membahayakan kesehatan. Secara umum, penyakit ginjal kronis terbagi menjadi dua jenis, yaitu penyakit ginjal kronis akut dan penyakit ginjal kronis (PGK). Penyakit ginjal kronis akut adalah penyakit yang membutuhkan diagnosis yang cepat dalam penanganannya dan memiliki resiko kematian yang tinggi [5]. Penyakit ginjal kronis merupakan gangguan fungsi ginjal yang berlangsung secara progresif dan permanen, sehingga menyebabkan penumpukan sisa metabolisme di dalam tubuh. Menurut penelitian [6], pada kondisi ini ginjal tidak mampu menjalankan fungsinya secara optimal, sehingga pasien memerlukan terapi hemodialisa untuk menggantikan peran ginjal yang menurun. Oleh karena itu, pendekatan yang bersifat holistik sangat diperlukan untuk menjaga kualitas hidup pasien dan mengurangi keluhan saat menjalankan terapi.

B. Random Forest

Random Forest dikenal sebagai salah satu algoritma yang sangat baik dalam proses klasifikasi. Algoritma ini bekerja berdasarkan pendekatan ensemble learning yang menggabungkan banyak decision tree untuk menghasilkan prediksi yang lebih stabil dan akurat. Dalam penelitian [7], dijelaskan bahwa Random Forest merupakan metode yang sangat cocok dengan data berskala besar dan kompleks, termasuk data medis. Keunggulan utama Random Forest adalah kemampuan dalam menangani data berdimensi tinggi serta menghasilkan informasi penting melalui variable importance, yang sangat membantu dalam identifikasi faktor faktor resiko penyakit. Oleh karena itu Random Forest menjadi salah satu algoritma pilihan dalam pengembangan model prediksi dibidang kesehatan.

C. Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah algoritma klasifikasi yang dirancang dalam memisahkan data secara optimal dengan cara memaksimalkan margin antar kelas. Algoritma ini bekerja dengan mencari batas pemisah terbaik (hyperplane) yang memaksimalkan jarak dan titik dari masing-masing kelas, khususnya pada data yang paling dekat dengan batas tersebut yang disebut support vectors. SVM sangat efektif dalam menangani data dengan pola kompleks, terutama ketika hubungan antar fitur tidak linear. Hal ini dimungkinkan melalui teknik yang dikenal sebagai kernel trick, yang memungkinkan data diproyeksikan ke ruang berdimensi tinggi agar dapat dipisahkan lebih baik, oleh karena itu juga SVM banyak digunakan dalam analisis data medis yang memerlukan klasifikasi yang akurat pada data yang berdimensi tinggi.

D. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah varian dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi masalah vanishing gradient pada pemrosesan data sekuensial. LSTM memiliki arsitektur khusus yang terdiri dari sel memori dan beberapa gerbang utama yang bekerja bersama untuk mengatur alur informasi. Mekanisme ini menjadikan LSTM unggul dalam memahami konteks temporal dan dependensi jangka panjang dalam data deret waktu seperti sinyal medis, teks, dan data sensor. Oleh karena itu, LSTM banyak digunakan dalam domain yang

membutuhkan prediksi dan klasifikasi akurat terhadap data berurutan berdimensi tinggi.

III. METODE

Pada penelitian ini digunakan metode Cross-Industry Standard Process for Data Mining (CRISP-DM). CRISP-DM merupakan metode yang bersifat iteratif dan fleksibel yang banyak digunakan dalam penelitian berbasis data mining dan machine learning. Metode ini terdiri dari enam tahap utama yang saling berkaitan dan dapat dilakukan secara berulang hingga diperoleh hasil model yang optimal. Berikut ini adalah gambaran dan penjelasan tahapan dari metodologi CRISP-DM:

A. Business Understanding

Pada Tahap ini bertujuan untuk memahami konteks bisnis atau permasalahan yang hendak diselesaikan. Dalam konteks penelitian ini, permasalahan yang diangkat adalah pentingnya deteksi dini penyakit ginjal kronis serta perlunya pengembangan model prediksi yang akurat dan mudah diakses oleh tenaga medis. Tujuan bisnis utama adalah mengembangkan sistem prediksi yang membantu proses diagnosis lebih cepat.

B. Data Understanding

Pada tahap ini dilakukan dengan bertujuan untuk mengeksplorasi dan memahami struktur data penyakit ginjal kronis yang digunakan. Data ini bersumber dari website UCI yang tujuannya adalah memastikan bahwa data memiliki kualitas dan informasi yang cukup baik untuk dilanjutkan ke proses berikutnya. Proses ini mencakup analisis awal yaitu, identifikasi jumlah fitur, identifikasi jenis data, pendeteksian missing values atau outlier, dan distribusi kelas target (sehat vs sakit).

C. Data Preparation

Pada tahap ini dilakukan pembersihan dan transformasi data agar data siap untuk digunakan dalam proses pelatihan model. Tahapan ini meliputi penanganan nilai hilang (missing values), normalisasi atau standarisasi data, encoding data kategorikal, pemisahan data menjadi data latih (training) dan data uji (testing), dan proses hyperparameter tuning. Tahap ini sangat penting untuk memastikan bahwa algoritma machine learning dapat bekerja secara optimal.

D. Modeling

Tahap ini merupakan proses utama dalam membangun model prediksi penyakit ginjal kronis menggunakan beberapa algoritma. Pada setiap model dilakukan pelatihan dan pengujian, disertai dengan hyperparameter tuning untuk mendapatkan performa terbaik.

- Random Forest* (RF): algoritma ensemble berbasis decision tree
- Support Vector Machine (SVM): algoritma klasifikasi dengan margin maksimum
- Long Short-Term Memory (LSTM): arsitektur deep learning untuk data sekuensial

E. Evaluation

Pada tahap ini dilakukan evaluasi terhadap performa model yang telah dibangun menggunakan confusion matrix yang memiliki beberapa nilai utama, yaitu Akurasi,

Precision, Recall, dan F1-Score. Hasil evaluasi ini akan digunakan untuk membandingkan ketiga model dan memilih model terbaik untuk diterapkan pada sistem prediksi berbasis web.

F. Deployment

Tahap deployment adalah implementasi model terbaik ke dalam aplikasi web berbasis Flask. Sistem ini akan memungkinkan pengguna untuk memasukkan data kesehatan tertentu, kemudian mendapatkan prediksi status terkait penyakit ginjal kronis secara langsung. Tujuannya adalah memberikan kemudahan akses terhadap teknologi prediktif bagi pengguna non-teknis.

IV. HASIL DAN PEMBAHASAN

A. Business Understanding

Tahapan Business Understanding yang telah dirancang sebelumnya bertujuan untuk membangun sebuah sistem prediksi penyakit ginjal kronis guna membantu tenaga medis dalam mendeteksi penyakit secara lebih dini dan akurat. Berdasarkan tujuan tersebut, sistem telah berhasil diimplementasikan dalam bentuk aplikasi prediksi berbasis web dengan menggunakan data hasil pemeriksaan medis pasien. Sistem ini memungkinkan pengguna, khususnya tenaga medis, untuk memasukkan data klinis pasien seperti tekanan darah, kadar kreatinin serum, albumin, dan parameter lainnya, kemudian mendapatkan hasil prediksi apakah pasien berpotensi mengalami penyakit ginjal kronis atau tidak. Dengan adanya sistem ini, proses identifikasi kondisi pasien menjadi lebih cepat, terutama dalam situasi yang membutuhkan respon dini. Hal ini diharapkan dapat membantu proses pengambilan keputusan medis secara lebih efisien dan mendukung langkah-langkah pencegahan serta penanganan yang tepat waktu.

B. Data Understanding

Tahap *data understanding* telah dilakukan beberapa proses pemahaman data penyakit ginjal kronis. Proses ini dilakukan dengan identifikasi jenis data dan identifikasi pembersihan data yang harus dilakukan. Pada penelitian ini digunakan data penyakit ginjal kronis dari UCI yang memiliki 26 kolom data. Data ini memiliki 25 fitur dan 1 label yang dapat digunakan dalam membantu pembangunan model. Pada fitur terdapat beragam tipe data dari integer, float, dan object. Hal ini dapat dilakukan analisis terkait isi dari masing-masing data untuk memastikan data layak digunakan. Proses analisis ini dilakukan dengan membagi kolom kategorikal dan numerik. Kolom kategorikal merupakan data yang memiliki tipe data object yang hanya memiliki beberapa jenis value atau dapat disebut unique value. Pada kolom kategorikal ini dilakukan visualisasi terhadap unique value yang dimiliki oleh setiap kolom. Berikut ini merupakan hasil visualisasi kolom kategorikal dalam data.

C. Data Preparation

Tahap data preparation adalah salah satu langkah yang paling krusial dalam alur CRISP-DM karena kualitas data secara langsung dapat mempengaruhi performa model yang dihasilkan. Data mentah yang diperoleh dari sumber eksternal umumnya masih memiliki berbagai permasalahan, seperti nilai kosong (*missing values*), inkonsistensi

penulisan, kesalahan tipe data, serta adanya atribut yang tidak relevan. Jika tidak ditangani dengan baik, kondisi ini dapat menyebabkan bias, menurunkan akurasi model, dan mengurangi keandalan sistem prediksi. Oleh karena itu, pada penelitian ini dilakukan runtutan proses untuk memastikan data siap digunakan dalam pemodelan. Tahapan yang dilakukan sebagai berikut:

- Pembersihan data, yaitu penghapusan kolom yang tidak relevan (seperti id), penyeragaman penulisan nilai kategorikal, serta perbaikan tipe data pada beberapa kolom yang terdeteksi salah format.
- Penanganan missing value, dengan cara yang berbeda sesuai karakteristik data: random sampling untuk fitur numerik dengan jumlah nilai kosong relatif banyak, dan mode imputation untuk fitur kategorikal dengan jumlah nilai kosong sedikit.
- Transformasi data kategorikal, menggunakan label encoding agar variabel kategorikal dapat diproses oleh algoritma pembelajaran mesin.
- Split data, pembagian data latih dan uji dengan tiga skenario rasio: 70:30, 80:20, dan 90:10.
- Hyperparameter tuning, untuk menentukan parameter terbaik pada algoritma SVM dan Random Forest menggunakan GridSearchCV dengan validasi silang 5-fold.

Dengan melakukan langkah-langkah tersebut, data mentah berhasil diubah menjadi clean dataset yang konsisten, bebas dari masalah nilai kosong, dan siap digunakan untuk proses pemodelan prediksi CKD.

D. Modeling

Tahap modeling adalah suatu proses inti dalam penelitian ini, yaitu membangun model prediksi menggunakan tiga algoritma, yaitu Random Forest, Support Vector Machine (SVM), dan Long Short-Term Memory (LSTM). Pada tahapan ini, data yang telah dipersiapkan sebelumnya dilatih dan diuji dengan tiga skenario pembagian data, yakni 70:30, 80:20, dan 90:10, dengan menggunakan parameter optimal yang diperoleh dari tahap hyperparameter tuning. Pada algoritma Random Forest dan SVM, proses pembangunan model dilakukan dengan memanfaatkan hasil parameter terbaik yang telah ditentukan sebelumnya. Parameter ini kemudian dipanggil melalui fungsi `best_estimator_` yang secara otomatis mengatur model agar bekerja dengan konfigurasi paling optimal. Model yang telah terbentuk digunakan untuk melakukan prediksi pada data uji sesuai dengan masing-masing rasio pembagian data.

Berbeda dengan dua algoritma tersebut, pada LSTM model dibangun secara langsung menggunakan pendekatan Sequential. Beberapa komponen penting ditetapkan dalam arsitektur, seperti jumlah unit neuron, fungsi aktivasi, dropout, dan jenis optimizer. Proses penyusunan arsitektur dilakukan melalui fungsi yang telah ditentukan, sedangkan pelatihan dan evaluasi dilakukan dengan memanfaatkan data latih dan data uji. Sebelum pelatihan, data terlebih dahulu diubah ke dalam bentuk tiga dimensi (3D) menggunakan fungsi `reshape` agar sesuai dengan kebutuhan input LSTM. Dengan demikian, ketiga model berhasil dibangun dengan konfigurasi terbaiknya masing-masing. Model LSTM berperan sebagai pembanding terhadap dua algoritma klasik (Random Forest dan SVM), sehingga dapat diketahui

performa relatif dari setiap pendekatan dalam memprediksi penyakit ginjal kronis.

E. Evaluation

Pada tahap evaluation dilakukan proses evaluasi berdasarkan akurasi,presisi,recall, dan f-1 score. Hasil dari setiap model ini akan dibandingkan dan ditentukan berdasarkan nilai yang dihasilkan untuk menentukan model terbaik yang dapat digunakan. Berikut ini merupakan salah satu contoh code yang digunakan dalam evaluasi model.

TABEL 1
(A)

No.	Model	Rasio	Hasil
1	SVM	70:30	Akurasi :0.966 Presisi :0.934 Recall :0.977 F1 Score :0.955
		80:20	Akurasi : 0.975 Presisi : 1.0 Recall : 0.928 F1 Score : 0.962
		90:10	Akurasi :0.95 Presisi :0.928 Recall :0.928 F1 Score
2	Random Forest	70:30	Akurasi : 0.991 Presisi : 1.0 Recall : 0.977 F1 Score : 0.988
		80:20	Akurasi : 0.975 Presisi : 1.0 Recall : 0.928 F1 Score : 0.962
		90:10	Akurasi : 0.975 Presisi : 1.0 Recall : 0.928 F1 Score : 0.962
3	LSTM	70:30	Akurasi : 0.975 Presisi : 0.955 Recall : 0.977 F1 Score : 0.966
		80:20	Akurasi : 0.975 Presisi : 0.9642 Recall : 0.9642 F1 Score : 0.964

	90:10	Akurasi : 0.925 Presisi : 0.923 Recall : 0.857 F1 Score : 0.888
--	-------	--

Berdasarkan hasil evaluasi, ketiga algoritma menunjukkan performa yang baik pada berbagai rasio pembagian data. Random Forest menjadi model paling unggul dan konsisten, terutama pada rasio 70:30 dengan akurasi 0.99. SVM juga memberikan hasil kompetitif pada rasio 80:20 dengan akurasi 0.975. LSTM mampu mencatat performa yang cukup baik pada rasio 70:30 dan 80:20, namun mengalami penurunan signifikan pada rasio 90:10 karena kebutuhan data latih yang lebih besar. Oleh karena itu, model Random Forest dengan pembagian data 70:30 dipilih sebagai model terbaik untuk tahap deployment sistem prediksi penyakit ginjal kronis berbasis Flask.

F. Deployment

Pada tahap deployment model prediksi penyakit ginjal yang telah dilatih disimpan dalam format .sav menggunakan joblib dan diimplementasikan melalui backend API berbasis Flask. API ini menerima input data kesehatan pengguna, memproses prediksi menggunakan model, lalu mengembalikan hasil dalam format JSON. Untuk meningkatkan transparansi, sistem juga dilengkapi dengan LIME yang menjelaskan kontribusi fitur terhadap setiap prediksi, sehingga hasil klasifikasi lebih mudah dipahami oleh pengguna.

GAMBAR 1
(A)

Frontend dikembangkan dengan HTML, Bootstrap, dan JavaScript untuk menyediakan form input yang responsif, mengirim data ke API, serta menampilkan hasil prediksi di browser.

V. KESIMPULAN

Proyek pengembangan sistem prediksi penyakit ginjal ini telah berhasil mencapai tujuan utama, yaitu membangun model klasifikasi yang akurat dan dapat diimplementasikan dalam bentuk aplikasi web interaktif. Model terbaik diperoleh melalui algoritma Random Forest dengan rasio pelatihan dan pengujian 70:30, menghasilkan akurasi sebesar 99.17% dan F1 Score sebesar 0.9885. Hasil ini menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengidentifikasi kondisi pasien terkait risiko penyakit ginjal. Sistem ini diimplementasikan melalui backend berbasis Flask dan frontend berbasis HTML dan Bootstrap, yang memungkinkan pengguna menginput data secara langsung dan menerima hasil prediksi secara real-time melalui tampilan antarmuka yang sederhana dan responsif. Untuk meningkatkan transparansi dan interpretabilitas, sistem mengintegrasikan metode LIME (Local Interpretable Model-Agnostic Explanations) guna menampilkan visualisasi kontribusi masing-masing fitur terhadap hasil prediksi. Penjelasan tersebut ditampilkan secara interaktif dalam halaman web agar mudah dipahami oleh pengguna. Dengan tercapainya akurasi tinggi, integrasi penjelasan model, serta kemudahan akses melalui web, maka seluruh tujuan dan rumusan masalah dalam penelitian ini dapat dinyatakan telah tercapai secara menyeluruh.

REFERENSI

- [1] H. Żórawska, A. Zhymaila, and J. Malyszko, "Definitions and classification of acute kidney injury, acute kidney disease, and chronic kidney disease," 2022.
- [2] V. Gliselda Kyneissia, "Diagnosis dan Manajemen Penyakit Ginjal Kronis (PGK)," Jul. 2021. [Online]. Available: <http://jurnalmedikahutama.com>
- [3] F. Arriyani and T. Wahyono Miko Yunis, "Faktor Risiko Penyakit Ginjal Kronis pada Kelompok Usia Dewasa : Literature Review," May 2023.
- [4] R. Komalasari, "Pemanfaatan Kecerdasan Buatan (Artificial Intelligence) Dalam Telemedicine: Dari Perspektif Profesional Kesehatan," 2022.
- [5] A. R. Syadiah, E. Febrina, and J. Levita, "Review Neutrophil Gelatinase-Associated Lipocalin (NGAL): Perannya sebagai Biomarker pada Kerusakan Ginjal Akut," *Jurnal Sains Farmasi & Klinis*, vol. 8, no. 1, p. 35, Apr. 2021, doi: 10.25077/jsfk.8.1.35-42.2021.
- [6] R. Dewi and A. Mustofa, "Penurunan Intensitas Rasa Haus Pasien Penyakit Ginjal Kronik Yang Menjalani Hemodialisa Dengan Menghisap Es Batu," *Ners Muda*, vol. 2, no. 2, p. 17, Aug. 2021, doi: 10.26714/nm.v2i2.7154.
- [7] J. Hu and S. Szymczak, "A review on longitudinal data analysis with random forest," Mar. 01, 2023, *Oxford University Press*. doi: 10.1093/bib/bbad002.