

Deteksi Dini Penyakit Ginjal Kronis Dengan Menggunakan Algoritma *Deep Learning*

Nurlaelatul Maulidah^{1*}, Hiya Nalatissifa², Kheri Agus Suseno³, Sabrina Ratu Aqilah⁴, Tia Winasti⁵

^{1,2,4,5} Fakultas Teknik dan Informatika, Sistem Informasi Akuntansi Kampus Kota Tegal, Universitas Bina Sarana Informatika, Tegal, Indonesia

³ Fakultas Teknik dan Informatika, Sistem Informasi Kampus Kota Tegal, Universitas Bina Sarana Informatika, Tegal, Indonesia

Email: ¹nurlaelatul.nlt@bsi.ac.id, ²hiya.hys@bsi.ac.id, ³kheri.kgs@bsi.ac.id,
⁴sabrinaaqilah04@gmail.com, ⁵tiawinasti@gmail.com

*Penulis Korespondensi: ¹nurlaelatul.nlt@bsi.ac.id

Abstrak

Penyakit Ginjal Kronis (PGK) merupakan salah satu masalah kesehatan serius dengan tingkat prevalensi yang terus meningkat di berbagai negara. Kondisi ini sering kali baru terdeteksi pada tahap lanjut, sehingga upaya deteksi dini sangat diperlukan untuk memperlambat perkembangan penyakit serta mengurangi risiko komplikasi. Penelitian ini mengkaji penerapan tiga pendekatan deep learning, yaitu *Artificial Neural Network* (ANN), *Long Short-Term Memory* (LSTM), dan *Convolutional Neural Network* (CNN), dalam klasifikasi data pasien untuk identifikasi awal PGK. Hasil kajian dari berbagai penelitian mutakhir menunjukkan bahwa metode ANN mampu memberikan hasil yang stabil ketika dipadukan dengan teknik seleksi fitur, sedangkan LSTM memiliki keunggulan dalam mengolah data berurutan sehingga efektif memprediksi perkembangan penyakit. Di sisi lain, CNN terbukti dapat mengekstraksi pola kompleks pada data medis dan meningkatkan akurasi sistem. Pendekatan gabungan atau ensemble yang mengintegrasikan lebih dari satu arsitektur juga dilaporkan mampu menghasilkan performa prediksi yang lebih tinggi dibandingkan metode tunggal. Temuan ini menegaskan bahwa integrasi teknik deep learning dengan strategi optimasi model dapat memberikan dukungan yang signifikan dalam sistem deteksi dini berbasis data medis, sehingga berpotensi membantu tenaga medis dalam proses pengambilan keputusan klinis yang lebih cepat dan tepat.

Kata kunci: *Penyakit Ginjal Kronis, Deteksi Dini, Artificial Neural Network, Long Short-Term Memory, Convolutional Neural Network, Deep Learning.*

Abstract

Chronic Kidney Disease (CKD) is a major global health concern with an increasing prevalence that significantly affects patients' quality of life and creates economic and social burdens. The disease is often diagnosed at an advanced stage, making early detection crucial to slow its progression and reduce the risk of severe complications. This study examines the application of three deep learning approaches—Artificial Neural Network (ANN), Long Short-Term Memory (LSTM), and Convolutional Neural Network (CNN)—for classifying patient data in the early identification of CKD. Findings from recent studies indicate that ANN performs consistently well when combined with feature selection techniques, while LSTM demonstrates superior capability in processing sequential data, enabling effective disease progression prediction. CNN, on the other hand, is highly effective in extracting complex patterns from medical data, thereby improving system accuracy. Furthermore, ensemble approaches that integrate multiple architectures have been reported to outperform individual models, producing more robust predictive performance. These insights highlight that the integration of deep learning methods with appropriate model optimization strategies can provide significant support for data-driven early detection systems, offering valuable assistance to healthcare professionals in making faster and more accurate clinical decisions.

Keywords: *Chronic Kidney Disease, Early Detection, Artificial Neural Network, Long Short-Term Memory, Convolutional Neural Network, Deep Learning*

1. PENDAHULUAN

Penyakit ginjal kronik (PGK) atau *Chronic Kidney Disease* (CKD) merupakan isu kesehatan global yang berada pada urutan ke-10 sebagai penyebab utama kematian di dunia menurut WHO (Nasution et al., 2025). Ginjal adalah organ vital yang berfungsi menjaga keseimbangan metabolisme, cairan, dan elektrolit. PGK merupakan kondisi gangguan fungsi ginjal yang terjadi lebih dari tiga bulan, ditandai oleh penurunan laju filtrasi glomerulus dan/atau adanya kelainan struktural pada organ ginjal (Suparjo et al., 2025). Ketika fungsi ginjal menurun dalam jangka panjang, ginjal tidak lagi mampu mempertahankan homeostasis tubuh sehingga menimbulkan komplikasi serius, termasuk uremia dan gagal ginjal stadium akhir (*End-Stage Renal Disease/ESRD*). Data dari *United States Renal Data System* (USRDS) menunjukkan bahwa lebih dari 871.000 pasien di Amerika Serikat telah dirawat akibat ESRD hingga akhir 2009. Di Indonesia, hasil Riset Kesehatan Dasar (Riskesdas) tahun 201 melaporkan prevalensi PGK Prevalensi Gagal Ginjal Kronis berdasarkan Diagnosis Dokter pada Penduduk Umur ≥ 15 Tahun di Indonesia sebesar 0,38%, serta prevalensi pada laki-laki (0,42%) sedikit lebih tinggi dibanding perempuan yaitu 0,35% (Riskesdas, 2018). Faktor risiko utama PGK di antaranya adalah umur, jenis kelamin, pendidikan, kebiasaan merokok, minum alkohol, riwayat hipertensi, riwayat diabetes melitus, riwayat keluarga dengan gagal ginjal kronik (Hasanah et al., 2023). Infeksi dan komplikasi sistemik lainnya juga berkontribusi besar terhadap tingginya angka mortalitas akibat ESRD.

Meningkatnya angka kejadian ini menuntut adanya sistem deteksi dini yang lebih efektif. Metode konvensional, seperti pemeriksaan laboratorium (misalnya eGFR dan kadar kreatinin serum) maupun pencitraan medis, sering kali membutuhkan biaya tinggi dan tidak selalu tersedia di fasilitas kesehatan primer. Oleh karena itu, diperlukan pendekatan alternatif yang mampu mendeteksi PGK sejak dini secara efisien, akurat, dan terjangkau. Seiring perkembangan teknologi, data mining dan *knowledge discovery in database* (KDD) telah menjadi solusi potensial untuk menggali informasi dari data medis. Proses ini melibatkan teknik klasifikasi, klusterisasi, dan regresi yang beririsan dengan *artificial intelligence* (AI), *machine learning* (ML), dan statistik untuk menemukan pola, tren serta pengetahuan dari sebuah data yang kompleks (Putra et al., 2023). Dalam dunia medis, metode tersebut dapat dimanfaatkan sebagai alat prediksi penyakit sekaligus pendukung pengambilan keputusan klinis yang lebih tepat dan cepat. Berbagai penelitian terdahulu telah menunjukkan keberhasilan teknik *machine learning* konvensional dalam mendeteksi PGK. Misalnya, penelitian dalam mendiagnosa PGK menggunakan algoritma C4.5 yang mampu mencapai akurasi hingga 96,67% (Ismail & Lestari, 2023). Sedangkan, penelitian PGK dengan menerapkan algoritma *K-Nearest Neighbor* (KNN) dengan akurasi 92,59% dan nilai presisi 89,85% (Indrianti et al., 2024).


Meskipun algoritma klasik cukup menjanjikan, namun deep learning memberikan hasil yang lebih unggul karena kemampuannya mengekstraksi pola non-linier dari data kompleks tanpa perlu intervensi manual (Maheswari & Gunawan, 2025). Arsitektur *Artificial Neural Network* (ANN), *Long Short-Term Memory* (LSTM), dan *Convolutional Neural Network* (CNN) telah banyak diimplementasikan dalam penelitian medis untuk diagnosis dan prediksi penyakit kronis. CNN secara khusus dibuat untuk memproses data berdimensi tinggi seperti citra dan video secara efisien. Arsitekturnya memanfaatkan lapisan konvolusi yang berfungsi mengekstraksi fitur-fitur spasial dari data input (Zebua et al., n.d.), LSTM efektif untuk beragam tugas pembelajaran yang menggunakan data sekuensial, jaringan saraf berulang dengan kemampuan menyimpan memori jangka pendek (Sawitri et al., 2025), sedangkan ANN unggul karena mampu menggali informasi dari data yang sulit didefinisikan atau tidak terstruktur (Henisaniyya et al., 2025). Penelitian sebelumnya, menunjukkan bahwa akurasi yang dihasilkan dengan menggunakan KNN dengan optimasi menggunakan Genetic Algorithm efektif mendeteksi PGK dengan tingkat akurasi sebesar 97,75% (Rukiastindari et al., 2025). Penelitian lain yang menggunakan Naive Bayes memperoleh akurasi 93,50%, presisi 85,23%, recall 100%, dan AUC 0,948 (Ermanto & Surojudin, 2025). Penelitian lain menunjukkan Hasil klasifikasi dataset menggunakan algoritma Decision Tree dan Generalized Linear Model menunjukkan kinerja yang luar biasa, dengan akurasi tertinggi sebesar 98,50% (Ikko et al., 2025). Penelitian selanjutnya menunjukkan Akurasi algoritma Decision Tree dengan seleksi fitur menggunakan Particle Swarm Optimization (PSO) lebih tinggi yaitu mencapai 0,967%, dibandingkan akurasi algoritma Decision Tree tanpa seleksi fitur Particle Swarm Optimization (PSO) yang hanya 0,95% (Fitri & Baita, 2025).

Berdasarkan penelitian-penelitian di atas, celah penelitian masih ditemukan karena studi sebelumnya umumnya hanya mengevaluasi satu model atau menggunakan algoritma *machine learning* klasik seperti *Naive Bayes*, SVM, dan KNN. Oleh karena itu, komparasi sistematis beberapa model deep learning pada *dataset* yang sama diperlukan untuk memperoleh gambaran kinerja yang lebih komprehensif. Secara keseluruhan, penelitian ini tidak hanya membandingkan performa dari tiga arsitektur *deep learning* yaitu ANN, LSTM, dan CNN, tetapi juga Penelitian menggunakan pendekatan kuantitatif melalui tahapan

preprocessing, normalisasi, dan *balancing* untuk mengoptimalkan prediksi serta meminimalkan bias. Evaluasi dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* dan memberikan analisis komparatif yang dapat menjadi rujukan bagi pengembangan sistem pendukung keputusan medis berbasis AI di Indonesia. Temuan penelitian diharapkan menjadi dasar ilmiah bagi pengembangan sistem deteksi PGK yang lebih andal.

2. METODE PENELITIAN

Tahapan dan perancangan pada penelitian ini menggunakan pendekatan terstruktur secara sistematis agar memastikan setiap tahap dapat terlaksana dengan baik. Tahapan pada penelitian ini dirancang berdasar urutan pelaksanaan, sehingga dapat melengkapi satu dengan lainnya agar tujuan yang



telah ditentukan terpenuhi. Berikut alur proses yang diterapkan dalam penelitian ini secara menyeluruh, diawali dari studi literatur, pengumpulan data, *preprocessing* data, normalisasi data, *balancing* implementasi model ANN, LSTM dan CNN, dan evaluasi model. Gambar 1 menyajikan diagram tahapan penelitian awal hingga akhir

Gambar 1. Tahapan Penelitian

2.1. Studi Literatur

Kegiatan ini dilaksanakan bertujuan sebagai awal dari proses penelitian serta analisis, sebagai penentu model ANN, LSTM dan CNN di komparasikan dari ketiga model tersebut sehingga akan menghasilkan hasil uji yang maksimal. Studi ini mengacu pada beragam studi sebelumnya untuk menilai efektivitas, tingkat akurasi, dan kelebihan dari masing-masing algoritma dalam mendeteksi masing-masing model dalam prediksi PGK.

2.2. Pengumpulan Data

Penelitian ini, data yang digunakan adalah data public. Data *public* sendiri merupakan dataset yang dapat diambil dari *repository* publik yang disepakati oleh para peneliti-peneliti data mining atau sumber data yang didapatkan peneliti dengan media perantara atau tidak secara langsung

2.3. Preprocessing Data

Tahap *preprocessing* merupakan salah satu langkah penting dalam penelitian berbasis *machine learning* dan *deep learning*. Data yang diperoleh dari sumber publik sering kali belum siap digunakan secara langsung karena terdapat nilai yang hilang, data berulang, atau format data yang tidak sesuai. Oleh sebab itu, dilakukan serangkaian proses pembersihan data agar model yang dibangun dapat memberikan hasil prediksi yang lebih akurat dan stabil. Seperti mengidentifikasi dan mengatasi nilai yang hilang (*missing values*) pada dataset, menghapus data duplikat, transformasi data dan pembagian dataset

2.4. Implementasi Model

Tahap implementasi model merupakan inti dari penelitian ini, di mana algoritma *deep learning* diterapkan untuk membangun sistem prediksi penyakit ginjal kronis (PGK). Tiga arsitektur yang digunakan adalah *Artificial Neural Network* (ANN), *Long Short-Term Memory* (LSTM), dan *Convolutional Neural Network* (CNN). Pemilihan ketiga model ini didasarkan pada keunggulannya masing-masing dalam menangani data tabular, sekuensial, maupun data dengan pola kompleks. Dengan tahapan yaitu implementasi algoritma *Artificial Neural Network* (ANN), implementasi algoritma *Long Short-Term Memory* (LSTM), implementasi algoritma *Convolutional Neural Network* (CNN) dan tahapan yang terakhir adalah evaluasi model dengan metrik akurasi, presisi, *recall*, *F1-score*, dan *Area Under Curve* (AUC). Evaluasi dilakukan untuk membandingkan performa ANN, LSTM, dan CNN secara langsung dalam mendeteksi CKD.

a. Implementasi Artificial Neural Network (ANN)

ANN merupakan arsitektur jaringan saraf tiruan dasar yang terdiri dari lapisan masukan (*input layer*), satu atau lebih lapisan tersembunyi (*hidden layers*), dan lapisan keluaran (*output layer*). Pada penelitian ini, data klinis pasien seperti tekanan darah, hemoglobin, dan kadar kreatinin dijadikan variabel masukan. Proses propagasi maju (*forward propagation*) dilakukan untuk menghitung keluaran, sedangkan propagasi balik (*backpropagation*) digunakan untuk memperbaiki bobot jaringan berdasarkan fungsi kehilangan (*loss*)

function). Optimizer Adam dipilih karena kemampuannya dalam mempercepat konvergensi dan menghindari jebakan minimum lokal. ANN digunakan sebagai baseline untuk melihat performa klasifikasi tabular dengan arsitektur sederhana.

b. Implementasi Long Short-Term Memory (LSTM)

LSTM adalah salah satu varian dari *Recurrent Neural Network* (RNN) yang mampu mengingat informasi dalam jangka panjang melalui penggunaan *memory cell* dan *gating mechanism*. Model ini cocok untuk data sekuensial atau data yang memiliki keterkaitan antarwaktu. Dalam penelitian ini, meskipun dataset CKD berbentuk tabular, LSTM tetap diuji untuk mengevaluasi kemampuannya dalam menangkap dependensi antaratribut medis. LSTM dibangun dengan beberapa unit memori pada lapisan tersembunyi dan dioptimalkan dengan fungsi aktivasi sigmoid dan tanh. *Output* akhir dipetakan ke dalam dua kelas, yaitu pasien dengan CKD dan non-CKD. Penggunaan LSTM diharapkan mampu mengurangi *information loss* yang sering terjadi pada RNN standar.

c. Implementasi *Convolutional Neural Network* (CNN)

CNN biasanya digunakan dalam pengolahan citra, tetapi penelitian terkini menunjukkan CNN juga efektif untuk data tabular karena kemampuannya mengekstraksi pola lokal melalui operasi konvolusi. Pada penelitian ini, CNN diimplementasikan dengan lapisan konvolusi satu dimensi (1D Convolution) untuk menangani data atribut klinis. Setiap filter konvolusi dirancang untuk menangkap interaksi antarfitur, seperti hubungan antara tekanan darah dan kadar kreatinin. Setelah itu, lapisan pooling digunakan untuk mengurangi dimensi dan mencegah overfitting. CNN dilengkapi dengan lapisan *fully connected* di bagian akhir untuk melakukan klasifikasi.

2.5. Evaluasi Model

Ketiga model dilatih menggunakan data latih dan data uji dengan metrik akurasi, presisi, *recall*, *F1-score*, dan *Area Under Curve* (AUC). Evaluasi dilakukan untuk membandingkan performa ANN, LSTM, dan CNN secara langsung dalam mendeteksi CKD.

3. HASIL DAN PEMBAHASAN

Pada bagian ini menyajikan temuan serta bahasan terkait proses pengumpulan dan pra-pemrosesan data, pengujian model, dan visualisasi data. Penelitian dilakukan melalui beberapa tahapan, dimulai dari pengumpulan data. Data yang terkumpul kemudian diproses melalui tahap *preprocessing* untuk membersihkan unsur yang tidak relevan, dilanjutkan dengan normalisasi data, lalu data tersebut dibagi menjadi data latih (*training set*) dan data uji (*testing set*) dengan pembagian data 80% data untuk pelatihan dan 20% data untuk pengujian. Tiga arsitektur yang digunakan yaitu *Artificial Neural Network* (ANN), *Long Short-Term Memory* (LSTM), dan *Convolutional Neural Network* (CNN), diterapkan untuk mendeteksi penyakit ginjal kronis, dan performanya dievaluasi menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-score*.

3.1. Pengumpulan Data

Penelitian ini, data yang digunakan adalah data *public*. Data *public* sendiri merupakan dataset yang dapat diambil dari *repository* publik yang disepakati oleh para peneliti-peneliti data mining atau sumber data yang didapatkan peneliti dengan media perantara atau tidak secara langsung. Data public pada penelitian ini menggunakan Chronic Kidney Disease Dataset dari Kaggle yang dapat diakses melalui <https://www.kaggle.com/datasets/mansoordaku/ckdisease/data>. Untuk Chronic Kidney Disease Dataset dari Kaggle, datanya sendiri terdiri dari 400 record dengan 26 atribut yaitu id, age, bp, sg, al, su, rbc, pc, pcc, ba, bgr, bu, sc, sod, pot, hemo, pcv, wc, rc, htn, dm, cad, appet, pe, ane, classification. Dimana atribut classification menjadi target. Di atribut target terdapat dua kelas yaitu pasien yang mengidap penyakit ginjal kronis dan pasien yang tidak mengidap penyakit ginjal kronis. Gambar 2 menyajikan tampilan data *View Chronic Kidney Disease Dataset* dalam format data CSV (*Comma Delimited*).

Tabel 1. *View Chronic Kidney Disease Dataset*

id	age	bp	sg	al	su	hemo	pcv	rc	...	classification
0	48.0	80.0	1.02	1.0	0.0	15.4	44	5.2	...	ckd
1	7.0	50.0	1.02	4.0	0.0	11.3	38		...	ckd
2	62.0	80.0	1.01	2.0	3.0	9.6	31		...	ckd
3	48.0	70.0	1.005	4.0	0.0	11.2	32	3.9	...	ckd
4	51.0	80.0	1.01	2.0	0.0	11.6	35	4.6	...	ckd


5	60.0	90.0	1.015	3.0	0.0	12.2	39	4.4	...	ckd
6	68.0	70.0	1.01	0.0	0.0	12.4	36		...	ckd
7	24.0		1.015	2.0	4.0	12.4	44	5	...	ckd
8	52.0	100.0	1.015	3.0	0.0	10.8	33	4.0	...	ckd
9	53.0	90.0	1.02	2.0	0.0	9.5	29	3.7	...	ckd
10	50.0	60.0	1.01	2.0	4.0	9.4	28		...	ckd
11	63.0	70.0	1.01	3.0	0.0	10.8	32	3.8	...	ckd
12	68.0	70.0	1.015	3.0	1.0	9.7	28	3.4	...	ckd
13	68.0	70.0				9.8			...	ckd
14	68.0	80.0	1.01	3.0	2.0	5.6	16	2.6	...	ckd
15	40.0	80.0	1.015	3.0	0.0	7.6	24	2.8	...	ckd
...
400	70.0	70.0	1.01	1.0	0.0				...	ckd

3.2. Preprocessing Data

Tahap *preprocessing* merupakan salah satu langkah penting dalam penelitian berbasis *machine learning* dan *deep learning*, khususnya pada data medis seperti *Chronic Kidney Disease* (CKD). Data yang diperoleh dari sumber publik sering kali belum siap digunakan secara langsung karena terdapat nilai yang hilang, data berulang, atau format data yang tidak sesuai. Oleh sebab itu, dilakukan serangkaian proses pembersihan data agar model yang dibangun dapat memberikan hasil prediksi yang lebih akurat dan stabil.

a. Mengatasi *Missing Values*

Langkah pertama dalam *preprocessing* adalah mengidentifikasi nilai yang hilang (*missing values*) pada dataset. Nilai kosong dapat terjadi akibat keterbatasan pencatatan klinis, kesalahan input data, atau faktor teknis lainnya. Apabila nilai kosong ditemukan pada atribut yang memiliki pengaruh besar terhadap diagnosis, maka dilakukan teknik imputasi. Untuk data numerik, imputasi dapat dilakukan dengan mengganti nilai kosong menggunakan rata-rata (*mean*) atau nilai tengah (*median*). Sementara itu, untuk data kategorikal digunakan modus, yaitu nilai yang paling sering muncul pada kolom tersebut [3], [4]. Apabila atribut yang memiliki banyak nilai kosong dianggap tidak relevan, maka atribut tersebut dapat dihapus agar tidak menimbulkan bias dalam pemodelan.



Gambar 3. *Mising Value Heatmap*

b. Menghapus Data Duplikat


Selain nilai kosong, keberadaan data duplikat juga menjadi masalah yang dapat memengaruhi hasil analisis. Duplikasi data dapat terjadi karena kesalahan pencatatan atau penggabungan dataset dari berbagai sumber. Data yang berulang dapat menurunkan kualitas dataset dan membuat model belajar pola yang salah atau berlebihan. Oleh karena itu, setiap entri dalam dataset diperiksa untuk memastikan tidak ada data pasien yang tercatat lebih dari satu kali. Jika ditemukan data duplikat, maka salah satu entri dihapus atau digabungkan jika mengandung informasi tambahan. Dengan cara ini, dataset yang digunakan menjadi lebih bersih dan representatif.

c. Transformasi Data

Tahap berikutnya adalah melakukan transformasi data agar lebih sesuai dengan kebutuhan algoritma pembelajaran mesin. Data medis sering kali terdiri dari gabungan data numerik dan kategorikal. Untuk dapat diproses oleh model ANN, LSTM, dan CNN, variabel kategorikal harus dikonversi ke dalam format numerik. Pada penelitian ini digunakan teknik label *encoding*, yaitu proses pemberian label angka pada setiap kategori. Misalnya, jenis kelamin pasien dengan kategori "Laki-laki" dan "Perempuan" akan diubah menjadi angka 0 dan 1 [8]. Transformasi ini bertujuan untuk memastikan bahwa semua variabel dapat dibaca oleh model tanpa mengurangi makna dari data aslinya. Contoh penerapan *labelling* dalam proses transformasi data ditampilkan pada Tabel 2. Gambar 5 Menyajikan hasil akhir *preprocessing* dataset.

Tabel 2. Potongan Contoh Labelling Data

id	age	bp	sg	al	su	rbc	pc	pcc	ba	...
0	0	40	3	3	1	0	1	1	0	0
1	1	5	0	3	4	0	1	1	0	0
2	2	54	3	1	2	3	1	1	0	0
3	3	40	2	0	4	0	1	0	1	0
4	4	43	3	1	2	0	1	1	0	0
...
395	395	47	3	3	0	0	1	1	0	0
396	396	34	2	4	0	0	1	1	0	0
397	397	8	3	3	0	0	1	1	0	0
398	398	11	1	4	0	0	1	1	0	0
399	399	50	3	4	0	0	1	1	0	0



Gambar 5. Hasil Akhir *Preprocessing* dataset

d. Pembagian Dataset

Setelah melalui tahap *preprocessing*, data yang sudah bersih dan siap pakai kemudian dibagi menjadi dua subset utama, yaitu data latih (*training set*) dan data uji (*testing set*). Pembagian dataset ini merupakan langkah penting untuk mengukur performa model *deep learning* dalam mendeteksi penyakit ginjal kronis (PGK). Pada penelitian ini, proporsi pembagian yang digunakan adalah 80% data untuk pelatihan dan 20% data untuk pengujian.

3.3. Implementasi Model

Tahap implementasi model merupakan inti dari penelitian ini, di mana algoritma *deep learning* diterapkan untuk membangun sistem prediksi penyakit ginjal kronis (PGK). Tiga arsitektur yang digunakan adalah *Artificial Neural Network* (ANN), *Long Short-Term Memory* (LSTM), dan *Convolutional Neural Network* (CNN). Pemilihan ketiga model ini didasarkan pada keunggulannya masing-masing dalam menangani data tabular, sekuensial, maupun data dengan pola kompleks.

a. Implementasi *Artificial Neural Network* (ANN)

Classification Report - ANN Model:				
	precision	recall	f1-score	support
0	1.00	0.91	0.95	46
1	0.93	1.00	0.96	54
accuracy			0.96	100
macro avg	0.97	0.96	0.96	100
weighted avg	0.96	0.96	0.96	100

Gambar 6. *Classification Report Artificial Neural Network* (ANN)

Laporan klasifikasi pada model ANN menunjukkan kinerja yang sangat baik dengan akurasi 96%. Pada kelas 0, model memiliki precision 1.00, recall 0.91, dan f1-score 0.95, sedangkan pada kelas 1 memperoleh precision 0.93, recall 1.00, dan f1-score 0.96. Nilai macro average dan weighted average yang sama-sama berada pada angka 0.96 menandakan bahwa performa model konsisten dan seimbang pada kedua kelas, sehingga model ANN mampu melakukan klasifikasi secara akurat dan stabil.

b. Implementasi *Long Short-Term Memory* (LSTM)

Classification Report - LSTM Model:				
	precision	recall	f1-score	support
0	1.00	0.91	0.95	46
1	0.93	1.00	0.96	54
accuracy			0.96	100
macro avg	0.97	0.96	0.96	100
weighted avg	0.96	0.96	0.96	100

Gambar 7. *Classification Report Long Short-Term Memory* (LSTM)

Laporan klasifikasi pada model LSTM menunjukkan performa yang sangat baik dengan akurasi 96%. Pada kelas 0, model mencapai precision 1.00, recall 0.91, dan f1-score 0.95, sedangkan pada kelas 1 memperoleh precision 0.93, recall 1.00, dan f1-score 0.96. Nilai macro average dan weighted average yang sama-sama berada pada angka 0.96 mengindikasikan bahwa model bekerja secara konsisten dan seimbang pada kedua kelas, sehingga LSTM mampu melakukan klasifikasi dengan akurat dan stabil.

c. Implementasi *Convolutional Neural Network* (CNN)

Classification Report - CNN Model:

	precision	recall	f1-score	support
0	1.00	0.98	0.99	46
1	0.98	1.00	0.99	54
accuracy			0.99	100
macro avg	0.99	0.99	0.99	100
weighted avg	0.99	0.99	0.99	100

Gambar 8. Classification Report Convolutional Neural Network (CNN)

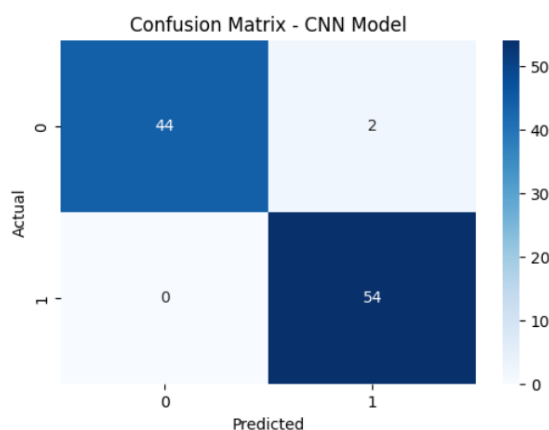
Laporan klasifikasi pada model CNN menunjukkan kinerja yang sangat unggul dengan akurasi 99%. Pada kelas 0, model mencapai precision 1.00, recall 0.98, dan f1-score 0.99, sementara pada kelas 1 memperoleh precision 0.98, recall 1.00, dan f1-score 0.99. Nilai macro average dan weighted average yang sama-sama berada pada angka 0.99 menegaskan bahwa model memiliki performa yang sangat konsisten, seimbang, dan akurat pada kedua kelas, sehingga CNN menjadi model dengan hasil prediksi terbaik di antara seluruh arsitektur yang diuji.

d. Evaluasi Model

Pada penelitian ini ketiga model dilatih menggunakan 80% data latih, dengan jumlah epoch dan batch size yang ditentukan melalui proses eksperimen awal. Fungsi loss yang digunakan adalah *binary cross-entropy* karena penelitian ini berfokus pada tugas klasifikasi biner. Setelah proses pelatihan selesai, model diuji menggunakan 20% data uji dan dievaluasi menggunakan metrik akurasi, presisi, recall, F1-score, serta Area Under Curve (AUC). Evaluasi ini dilakukan untuk membandingkan secara langsung kinerja ANN, LSTM, dan CNN dalam mendeteksi CKD. Pada tahap tersebut, diperoleh hasil evaluasi sebagai berikut:

Tabel 3. Evaluasi Performa Model

Model	Accuracy Score
Convolutional Neural Network (CNN) Model	98%
Artificial Neural Network (ANN)	97%
Long Short-Term Memory (LSTM) Model	96%



Gambar 6. Confusion Matrix Convolutional Neural Network (CNN)

Dari gambar tersebut diatas dapat kita simpulkan bahwa Model CNN menunjukkan performa yang sangat baik, terutama pada kelas positif (PGK), ditunjukkan dengan FN = 0. Tingkat kesalahan model sangat rendah, hanya terdapat 2 salah prediksi (FP) dengan nilai True Negative (TN) = 44 dan True Positive

(TP) = 54. Secara keseluruhan, model mampu membedakan kelas dengan sangat akurat, baik untuk pasien PGK maupun non-PGK.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa model Convolutional Neural Network (CNN) memiliki kinerja paling optimal dalam klasifikasi penyakit ginjal kronis, dengan tingkat akurasi tertinggi sebesar 98% dibandingkan ANN dan LSTM. Secara umum, ketiga model deep learning mampu memberikan hasil prediksi yang baik sehingga berpotensi mendukung proses deteksi dini dan pengambilan keputusan di bidang kesehatan. Penerapan metode ini diharapkan dapat menjadi dasar pengembangan sistem pendukung keputusan dan sistem pakar yang lebih akurat dan adaptif dalam mendeteksi penyakit ginjal kronis di fasilitas pelayanan kesehatan.

REFERENSI

- Ermanto, & Surojudin, N. (2025). *Jurnal Informatika Ekonomi Bisnis Perbandingan Metode Klasifikasi Dalam Memprediksi Penyakit Ginjal Kronis*. 7, 715–723. <https://doi.org/10.37034/Infob.V7i3.1263>
- Fitri, L. A., & Baita, A. (2025). *Optimization Of Decision Tree Algorithm For Chronic Kidney Disease Classification Based On Particle Swarm Optimization (Pso)*. 9(1).
- Hasanah, U., Dewi, N. R., Pakarti, A. T., & Inayati, A. (2023). *Analisis Faktor-Faktor Risiko Terjadinya Penyakit Ginjal Kronik Pada Pasien Hemodialisis*. 8(2), 96–103. <https://doi.org/10.52822/Jwk.V8i2.531>
- Henisaniyya, N., Pertiwi, C., Desiani, A., Amran, A., & Arhami, M. (2025). *Klasifikasi Class Thyroid Menggunakan Algoritma Id3 Dan Artificial Neural Network (Ann) Classification Of Thyroid Class Using Id3 Algorithm And Artificial*. 14, 1–14.
- Ikko, I., Rizky, M., Purwaningtyas, W. F., Rahmawati, M., Sains, F., Buana, U. W., Kesehatan, F. I., & Buana, U. W. (2025). *Analisis Komparatif Algoritma Klasifikasi Untuk Prediksi Dini Penyakit*. 9(2), 89–95.
- Indrianti, N. F., Ningsih, A. K., Ilyas, R., Informatika, T., Jenderal, U., Yani, A., Barat, J., & Neighbor, K. (2024). *Implementasi Data Mining Untuk Klasifikasi Penyakit Gagal Ginjal Kronis Menggunakan Metode K-Nearest Neighbor*. 8(2), 2255–2260.
- Ismail, N., & Lestari, S. (2023). *Mendiagnosis Penyakit Ginjal Kronis Menggunakan*. 25–31.
- Maheswari, S., & Gunawan, D. (2025). *Deteksi Dini Kanker Kulit Menggunakan Cnn, Dnn, Dan Efficientnet: Pendekatan Deep Learning Berbasis Web 1) 1,2)*. 10(2), 932–944.
- Nasution, M. Z., Sikumbang, E. S., & Gurning, F. P. (2025). *Analisis Tren Penyakit Gagal Ginjal Kronik Peserta Bpjs Dan Dampaknya Pada Pembiayaan Kesehatan Indonesia Analysis Of Chronic Kidney Disease Trends Among Bpjs Participants And Their Impact On Indonesia ' S Health Financing System*. 8(7), 4308–4317. <https://doi.org/10.56338/Jks.V8i7.7798>
- Putra, R. F., Sandra, R., Budiman, Rahayu, P. W., Bangsa, T. A., & Zulfadhilah, Muhammad Choirina, P. (2023). *Data Mining - Algoritma Dan Penerapannya* (Efitra & Sepriano (Eds.)). Pt Sonpedia Publishing Indonesia. [https://books.google.co.id/books?hl=id&lr=&id=Zlhgeaaqbj&oi=fnd&pg=pa22&dq=seiring+p+erkembangan+teknologi,+data+mining+dan+knowledge+discovery+in+database+\(kdd\)+telah+menjadi+solusi+potensial+untuk+menggal+informasi+dari+data+medis.+proses+ini+melibatkan+teknik+klasifikasi,+klasterisasi,+dan+regresi+yang+beririsan+dengan+artificial+intelligence+\(ai\),+machine+learning+\(ml\),+dan+statistik+&ots=Tzrj8ntmj7&sig=Lddmsuiuanhvdlbbjrkpxz621y&redir_esc=y#v=onepage&q&f=false](https://books.google.co.id/books?hl=id&lr=&id=Zlhgeaaqbj&oi=fnd&pg=pa22&dq=seiring+p+erkembangan+teknologi,+data+mining+dan+knowledge+discovery+in+database+(kdd)+telah+menjadi+solusi+potensial+untuk+menggal+informasi+dari+data+medis.+proses+ini+melibatkan+teknik+klasifikasi,+klasterisasi,+dan+regresi+yang+beririsan+dengan+artificial+intelligence+(ai),+machine+learning+(ml),+dan+statistik+&ots=Tzrj8ntmj7&sig=Lddmsuiuanhvdlbbjrkpxz621y&redir_esc=y#v=onepage&q&f=false)
- Riskesdas. (2018). Laporan Nasional Riskesdas. *Kementerian Kesehatan RI - Badan Penelitian Dan Pengembangan Kesehatan*. https://repository.badankebijakan.kemkes.go.id/Id/Eprint/3514/1/Laporan_Riskesdas_2018_Nasional.Pdf
- Rukiastiandari, S., Rohimah, L., & Mutia, F. (2025). *Infotek : Jurnal Informatika Dan Teknologi Model Hibrida K-Nearest Neighbors Berbasis Genethic Algorithm Untuk Prediksi Penyakit Ginjal Kronis Penyakit Merupakan Salah Satu Penyebab Utama Morbiditas Dan Mortalitas Di Seluruh Dunia Dengan Meningkatnya Popu*. 8(1), 44–55.
- Sawitri, D., Elektro, P. T., Teknik, F., Komputer, D., & Medan, U. H. (2025). *Peran Deep Learning Dan Big Data Dalam Mendekteksi Masalah Keuangan Masalah Keuangan*. 6(1), 193–207. <https://doi.org/10.46576/Djtechno>

Suparjo, Mulyadi, A., & Khasanah, D. U. (2025). Pengaruh Edukasi Manajemen Penyakit Kronis Terhadap Pengetahuan Dan Sikap Masyarakat Dalam Pencegahan Komplikasi Penyakit Ginjal Kronis. *Jurnal Update Keperawatan*, 5(1), 101–106.

Zebua, R. S. Y., Utomo, D. T., Akmal, S., Ayuningtyas, A., Juarsa, R. P., Arifianto, M. A. S., Rhomadhona, H., Aprianti, W., & Kusmendar. (N.D.). *10 Metode Spk Favorit Di Masa Depan* (M. I. Al Kutsi (Ed.)). Cv Hei Publishing Indonesia. https://www.researchgate.net/profile/Rahmadini-Juarsa-2/publication/382831100_10_Metode_Spk_Favorit_Di_Masa_Depan/links/674d7a50a7fbc259f1a5c625/10-Metode-Spk-Favorit-Di-Masa-Depan.pdf