



EFISIENSI PSO DALAM PENGOPTIMALAN NEURAL NETWORK UNTUK CKD

Titin Prihatin¹, Sartini², Witriana Endah Pangesti³, Yudhistira³, Rachmat Suryadithia³

^{1,2,3,4,5}Universitas Bina Sarana Informatika

^{1,2,3,4,5}Jl. Kramat Raya No. 98, Senen, Jakarta Pusat 10450.

Email : titin.tpn@bsi.ac.id¹, sartini.sar@bsi.ac.id², witriana.weg@bsi.ac.id³,
yudhistira.yht@bsi.ac.id⁴, rachmat.rcs@bsi.ac.id⁵

ABSTRAK

Penyakit Ginjal Kronis (PGK) sering kali terdeteksi pada tahap lanjut, ketika pengobatan menjadi lebih sulit. Tantangan dalam mendeteksi dini PGK terletak pada gejalanya yang tidak signifikan pada tahap awal. Berbagai metode dan algoritma telah dikembangkan untuk meningkatkan akurasi prediksi PGK, namun metode Neural Network (NN) belum dioptimalkan secara efektif dengan algoritma optimasi. Penelitian ini bertujuan untuk mengkaji penggunaan Particle Swarm Optimization (PSO) dalam mengoptimalkan model NN untuk klasifikasi dan diagnosis PGK. Evaluasi model dilakukan dengan membandingkan hasil performa sebelum dan sesudah optimasi menggunakan metrik akurasi, precision, recall, dan AUC. Hasil optimasi menggunakan PSO berhasil meningkatkan akurasi model dari 98,00% menjadi 99,00%, serta meningkatkan precision dari 95,15% menjadi 97,50%. Model NN memiliki kemampuan yang sangat baik dalam mendeteksi PGK baik sebelum maupun sesudah optimasi. Meskipun peningkatan performa tidak terlalu signifikan, PSO terbukti efektif dalam mengurangi kesalahan positif palsu. Penelitian ini menyimpulkan bahwa kombinasi NN dan PSO dapat meningkatkan akurasi prediksi PGK dan memberikan wawasan penting mengenai variabel prediktor yang paling berpengaruh. Penelitian lanjutan diharapkan dapat menguji model pada dataset yang lebih besar dan beragam, serta mengeksplorasi metode optimasi lain untuk meningkatkan hasil prediksi.

Kata kunci : Chronic Kidney Disease, Efisiensi PSO, NN, Pengoptimalan NN.

ABSTRACT

Chronic Kidney Disease (CKD) is often detected at an advanced stage, when treatment becomes more difficult. The challenge in early detection of CKD lies in the insignificance of the symptoms in the early stages. Various methods and algorithms have been developed to improve the accuracy of CKD predictions, but the Neural Network (NN) method has not been optimized effectively with algorithm optimization. This study aims to examine the use of Particle Swarm Optimization (PSO) in optimizing NN models for CKD classification and diagnosis. Model evaluation is carried out by comparing performance results before and after optimization using accuracy, precision, recall and AUC metrics. The results of optimization using PSO succeeded in increasing model accuracy from 98.00% to 99.00%, as well as increasing precision from 95.15% to 97.50%. The NN model has excellent capabilities in detecting CKD both before and after optimization. Although the performance improvement is not very significant, PSO is proven to be effective in reducing false positive errors. This study concludes that the combination of NN and PSO can improve the accuracy of CKD predictions and provide important insights into the most influential predictor variables. It is hoped that further research will be able to test the model on larger and more diverse datasets, as well as explore other optimization methods to improve prediction results.

Kata kunci : Chronic Kidney Disease, NN, NN Optimization, PSO Efficiency.

1. PENDAHULUAN

Penyakit Ginjal Kronis (PGK) adalah kondisi medis di mana ginjal mengalami penurunan fungsi secara bertahap selama periode waktu yang lama. Ginjal memiliki

peran penting dalam menyaring limbah dan racun dari darah, serta mengatur keseimbangan cairan, elektrolit, dan tekanan darah. Pada PGK, kemampuan ginjal untuk menjalankan fungsi-fungsi ini menurun secara bertahap sehingga terjadi akumulasi racun dalam tubuh



yang dapat menyebabkan berbagai komplikasi serius (Rady & Anwar, 2019). PGK umumnya berkembang secara perlahan dan sering kali tidak menunjukkan gejala yang signifikan pada tahap awal terkena penyakit ini. Penyakit ini sering kali baru terdeteksi setelah mencapai stadium lanjut dengan kondisi serius yang dapat berakibat fatal jika tidak ditangani dengan baik, dan akan mengakibatkan kerusakan ginjal yang sangat parah dan sulit untuk diobati (Arif-UI-Islam & Ripon, 2019). PGK dapat disebabkan oleh berbagai faktor risiko seperti diabetes, hipertensi, infeksi ginjal berulang, dan kondisi medis lainnya yang merusak struktur dan fungsi ginjal (Akben, 2019). PGK merupakan penyakit yang sulit disembuhkan karena sifatnya yang progresif dan kronis (Elhoseny, Shankar, & Uthayakumar, 2019). Kerusakan ginjal yang terjadi pada PGK bersifat permanen, artinya tidak dapat sepenuhnya dipulihkan (Saha, Gourisaria, & Harshvardhan, 2022). Pengobatan PGK lebih berfokus pada mengontrol gejala, memperlambat perkembangan penyakit, dan mencegah komplikasi lebih lanjut (Revathy, Bharathi, Jeyanthi, & Ramesh, 2019).

Salah satu tantangan utama dalam mendeteksi PGK adalah gejalanya yang sering kali tidak terlihat pada tahap awal (A, S, Rangarao, & Saranya, 2019). Pada banyak kasus, PGK berkembang secara perlahan dan tidak menimbulkan gejala yang mencolok hingga ginjal mengalami kerusakan yang signifikan (Alaiad, Najadat, Mohsen, & Balhaf, 2020). Gejala PGK yang muncul umumnya bersifat nonspesifik, seperti kelelahan, penurunan nafsu makan, mual, muntah, pembengkakan di kaki atau pergelangan kaki, serta perubahan dalam buang air kecil (Qin et al., 2020). Karena gejala-gejala ini bisa mirip dengan kondisi medis lain, PGK sering kali tidak terdiagnosis hingga mencapai tahap lanjut di mana kerusakan ginjal sudah sangat parah (Pramanik, Khare, & Gourisaria, 2021). Keterlambatan dalam diagnosis ini membuat PGK menjadi penyakit yang berbahaya, karena pada saat gejala mulai tampak pilihan pengobatan yang tersedia mungkin sudah sangat terbatas (Senan et al., 2021). Oleh karena itu, deteksi dini melalui pemeriksaan rutin dan pengelolaan risiko sangat penting dalam mencegah perkembangan PGK ke tahap yang lebih parah (Hosseinzadeh et al., 2021). Deteksi dini telah dilakukan oleh para peneliti dengan berbagai macam metode, algoritma dan teknik telah dikembangkan dalam upaya

meningkatkan akurasi dan efisiensi deteksi PGK (Chittora et al., 2021).

Penelitian PGK yang sudah dilakukan dengan kombinasi *Support Vector Machine* (SVM) dan *Feature Selection* (Purwaningsih, 2022). Penelitian baru-baru ini pada tahun 2024 dilakukan dengan metode SVM dan *Particle Swarma Opimization* (PSO) (Wijaya, 2024), *Naïve Bayes* dan PSO (Nurdin, Suhardjono, Wuryanto, Yuliandari, & Sugiarto, 2024), *K-Nearest Neighbour* (KNN) dan PSO (Widodo, Brawijaya, & Samudi, 2024), dan penelitian terakhir di tahun 2024 menggunakan *Decission Tree* dan PSO (Widiati, Iriadi, Ariyati, Nawawi, & Sugiono, 2024). Dari hasil metode pengoptimalan dengan menggunakan metode PSO hasil yang didapat dari penelitian sebelumnya sangat meningkat dari metode tanpa optimasi dengan nilai akurasi mencapai 95,75 sampai 99,75. Berbagai metode dan algoritma telah dikembangkan, akan tetapi penggunaan model berbasis kecerdasan buatan (*Artificial Intelligence/AI*) seperti *Neural Network* (NN) belum pernah dioptimalkan dengan metode PSO pada penelitian PGK.

Neural Network merupakan metode yang populer dalam klasifikasi dan prediksi penyakit karena kemampuannya dalam mempelajari pola kompleks dari data medis. Namun, salah satu tantangan utama dalam penerapan NN adalah pengoptimalan parameter dan struktur model agar menghasilkan performa yang maksimal. Dalam konteks ini PSO menjadi salah satu metode yang efektif untuk mengatasi masalah optimisasi pada NN. PSO adalah algoritma berbasis populasi yang terinspirasi oleh perilaku sosial hewan, seperti kawanan burung yang bertujuan mencari solusi optimal melalui iterasi yang adaptif dan efisien.

Beberapa penelitian terdahulu telah menunjukkan keberhasilan PSO dalam meningkatkan kinerja pada berbagai aplikasi, termasuk di bidang medis. Namun, penerapan PSO secara spesifik untuk pengoptimalan NN dalam deteksi PGK masih belum banyak dieksplorasi. Oleh karena itu, penelitian ini bertujuan untuk mengkaji efisiensi PSO dalam pengoptimalan NN untuk diagnosis PGK, dengan harapan dapat memberikan kontribusi signifikan dalam pengembangan model prediksi PGK yang lebih akurat dan efisien.

Lingkup permasalahan dalam penelitian ini meliputi penerapan PSO pada NN untuk klasifikasi PGK dengan evaluasi kinerja model yang dihasilkan, serta analisis perbandingan dengan metode optimasi lainnya yang telah digunakan dalam penelitian terkait. Metode



penelitian yang digunakan melibatkan eksperimen simulasi dengan dataset PGK yang tersedia serta evaluasi performa model menggunakan metrik akurasi, sensitivitas, spesifisitas, dan nilai prediktif positif dan negatif. Pendekatan ini diharapkan tidak hanya dapat memperlihatkan keunggulan kombinasi NN dan PSO, tetapi juga memberikan wawasan baru bagi pengembangan model AI dalam bidang kesehatan, khususnya untuk deteksi dini PGK.

2. METODE PENELITIAN

Bagian metode ini akan menjelaskan secara rinci langkah-langkah penelitian yang dilakukan dalam mengkaji efisiensi PSO dalam pengoptimalan NN untuk diagnosis PGK. Penelitian ini mencakup beberapa tahap utama mulai dari pemilihan subjek penelitian, pengumpulan dan pengolahan data, hingga implementasi dan evaluasi model.

2.1 Subjek Penelitian dan Sumber Data

Penelitian ini menggunakan dataset yang berkaitan dengan PGK. Dataset yang digunakan diperoleh dari sumber data UCI *Repository*, yang merupakan kumpulan data medis yang relevan dan valid untuk penelitian PGK. Dataset ini mencakup beberapa variabel penting, seperti usia, jenis kelamin, tekanan darah, kadar gula darah, kadar kreatinin, dan lainnya yang dianggap relevan untuk diagnosis PGK.

Subjek penelitian terdiri dari 250 pasien dengan diagnosis PGK dan 150 pasien non-PGK sebagai kontrol. Pengambilan data dilakukan secara retrospektif dengan memanfaatkan data rekam medis yang sudah ada dengan total jumlah data sebesar 400 pasien.

2.2 Alur Penelitian

Berikut adalah tahapan proses yang ditempuh dalam penelitian ini:

1. Pengumpulan Data

Pengumpulan data dilakukan dengan mengakses database medis dari UCI *Repository*. Data yang dikumpulkan kemudian dipreproses untuk memastikan kualitas dan kesesuaian dengan tujuan penelitian. Tahap *preprocessing* mencakup penanganan *missing data*, normalisasi data, dan pengkodean variabel kategori.

2. Pembagian Data

Dataset dibagi menjadi dua bagian utama yaitu data latih dan data uji, dengan proporsi 80% dan 20% (data latih dan data uji). Pembagian ini dilakukan secara acak untuk memastikan representasi yang seimbang antara

data latih dan data uji.

3. Pengembangan Neural Network

Model NN dikembangkan dengan menggunakan arsitektur dasar yang terdiri dari beberapa lapisan (*input*, *hidden*, dan *output*). Struktur model termasuk jumlah *neuron* di setiap lapisan, dipilih berdasarkan eksperimen awal dan literatur yang relevan. Fungsi aktivasi, optimasi, dan parameter lainnya ditetapkan untuk memaksimalkan performa model dalam melakukan klasifikasi PGK.

4. Penggunaan PSO untuk Optimasi

PSO diterapkan untuk mengoptimalkan parameter dan struktur NN. Parameter yang dioptimalkan termasuk *learning rate*, jumlah *neuron* pada setiap lapisan *hidden*, dan parameter lainnya yang berpotensi mempengaruhi performa model. Proses optimasi dilakukan dengan mengiterasi PSO hingga mencapai solusi optimal atau hingga memenuhi kriteria *konvergensi* yang telah ditetapkan.

5. Evaluasi Model

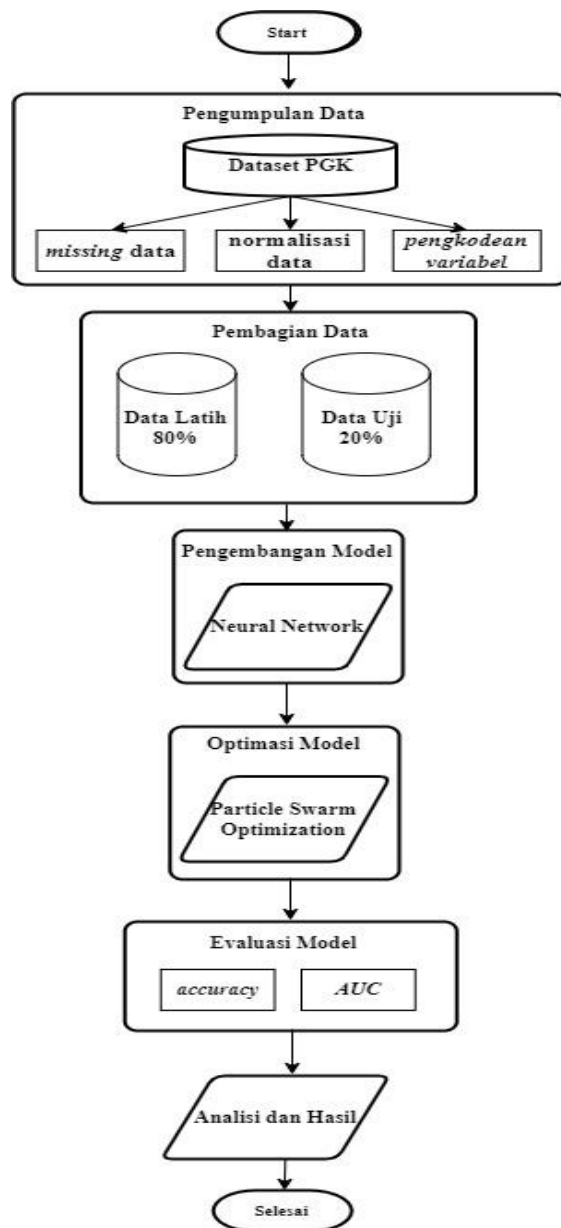
Model yang telah dioptimalkan dievaluasi menggunakan data uji untuk mengukur akurasi, sensitivitas, spesifisitas, serta nilai prediktif positif dan negatif. Metode evaluasi ini bertujuan untuk memastikan model yang dihasilkan tidak hanya akurat tetapi juga mampu mendeteksi PGK dengan efisiensi yang tinggi. Selain itu, hasil performa model dengan PSO dibandingkan dengan model NN tanpa optimasi PSO.

6. Analisis dan Interpretasi Hasil

Hasil evaluasi model kemudian dianalisis untuk menentukan efisiensi PSO dalam mengoptimalkan NN. Analisis dilakukan dengan membandingkan hasil yang diperoleh dengan hasil dari metode optimasi lain yang telah digunakan pada penelitian terkait. Penelitian ini juga menganalisis kontribusi penggunaan PSO dalam meningkatkan performa model NN dibandingkan dengan metode optimasi lainnya.

2.3 Gambar Alur Penelitian

Di bawah ini adalah gambar alur penelitian yang menjelaskan secara visual langkah-langkah yang dilakukan dalam penelitian ini.



Gambar 1. Alur Penelitian

3 HASIL DAN PEMBAHASAN

3.1 Pengumpulan dan Pembagian Data

Pada tahap ini, data yang digunakan dalam penelitian ini dikumpulkan dari sumber data yang terpercaya, yaitu UCI Repository. Dataset yang diperoleh terdiri dari 400 sampel dengan 250 sampel pasien yang didiagnosis mengalami PGK dan 150 sampel pasien yang tidak mengalami PGK. Setelah data berhasil dikumpulkan, langkah selanjutnya adalah melakukan preprocessing data. Dengan hasil data yang sudah dilakukan pengkodean variabel kategori seperti Gambar 2.

Gambar 2. Pengkodean Variabel Kategori

Setelah itu hasil dari setelah dilakukan *missing* dan normalisasi data terlihat pada Gambar 3.

Dengan data yang sudah diproses, dataset kemudian dibagi menjadi dua bagian utama, yaitu data latih dan data uji, dengan perbandingan 80% untuk data latih dan 20% untuk data uji. Pembagian ini dilakukan secara

class	binominal
age	integer
bp	integer
sg	integer
al	integer
su	integer
rbc	integer
pc	integer
pcc	integer
ba	integer
bgr	integer
bu	integer
sc	integer
sod	integer
pot	integer
hemo	integer
pcv	integer
wc	integer
rc	integer
htn	integer
dm	integer
cad	integer
appet	inteoer

acak untuk menjaga keseimbangan dan representativitas data dalam model yang akan dikembangkan.

Penelitian ini melibatkan sejumlah variabel yang relevan untuk diagnosis PGK. Variabel-variabel tersebut dikelompokkan menjadi dua kategori utama, yaitu variabel prediktor dan variabel target. Variabel prediktor mencakup berbagai parameter medis yang diukur dalam format numerik (*integer*), sedangkan variabel target atau kelas adalah variabel biner yang menunjukkan status diagnosis PGK pada pasien.

Variabel prediktor meliputi *age* (usia pasien dalam tahun), *bp* (tekanan darah dalam mmHg), *sg* (spesifik gravitasi urine), *al* (tingkat albumin dalam urine), *su* (tingkat gula dalam urine), *rbc* (jumlah sel darah merah), *pc* (hitungan platelet), *pcc* (kehadiran gips pada urin), *ba* (kehadiran bakteri dalam urin), *bgr* (kadar gula darah acak), *bu* (tingkat urea darah), *sc* (tingkat kreatinin serum), *sod* (kadar natrium serum), *pot* (kadar kalium serum), *hemo* (tingkat



hemoglobin), pcv (volume sel padat), wc (jumlah sel darah putih), rc (jumlah sel darah merah), htn (riwayat hipertensi), dm (riwayat diabetes mellitus), cad (riwayat penyakit arteri koroner), appet (tingkat nafsu makan pasien).

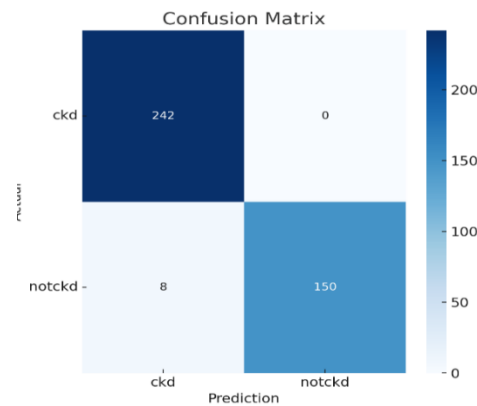
Variabel target class merupakan variabel biner yang menunjukkan status diagnosis PGK, di mana 'binominal' menunjukkan apakah pasien didiagnosis dengan PGK atau tidak.

age	bp	sg	al	su	rbc	pc	ba	bgr	bu	sc	sod	pot	hemo	pcr	wc	rc	htn	dm	cad	appet	pe	ane	
48	70	1005	4	0	1	2	1	2	117	56	4	111	2.500	11	32	6700	4	1	2	2	2	1	1
60	90	1015	3	0	1	1	2	2	74	25	1	142	3.200	12	39	7800	4	1	1	2	1	1	2
24	76	1015	2	4	1	2	2	2	410	31	1	138	5	12	44	6900	5	2	1	2	1	1	2
63	70	1010	3	0	2	2	1	2	380	60	3	131	4.200	11	32	4500	4	1	1	2	2	1	2
68	70	1015	3	1	1	1	1	2	208	72	2	138	5.800	10	28	12200	3	1	1	1	2	1	2
68	70	1017	1	0	1	1	2	2	98	86	5	135	3.400	10	39	8426	5	1	1	1	2	1	2
68	80	1010	3	2	1	2	1	1	157	90	4	130	6.400	6	16	11000	3	1	1	1	1	1	2
61	80	1015	2	0	2	2	2	2	173	148	4	135	5.200	8	24	9200	3	1	1	1	2	1	1
69	70	1010	3	4	1	2	2	2	264	87	3	130	4	13	37	9900	4	1	1	1	1	1	2
45	70	1010	0	0	1	1	2	2	148	20	1	138	5	13	39	8426	5	2	2	2	1	1	2
54	80	1010	3	0	2	2	2	2	207	77	6	134	4.800	10	28	8426	5	1	1	2	2	1	2
54	80	1020	3	0	1	2	2	2	208	89	6	130	4.900	9	39	8426	5	1	1	2	2	1	2
73	70	1005	0	0	1	1	2	2	70	32	1	125	4	10	29	18900	4	1	1	2	1	1	2
53	60	1017	1	0	1	1	2	2	91	114	3	142	4.300	9	28	11000	4	1	1	2	2	1	1
54	100	1015	3	0	1	1	1	2	162	66	2	136	4.400	10	33	8426	5	1	1	2	2	1	2
35	80	1005	3	0	2	1	2	2	148	57	3	138	5	10	28	8426	5	2	2	2	1	1	2
76	70	1015	3	4	1	2	1	2	148	164	10	131	4.400	10	30	11300	3	1	1	1	2	1	2
67	80	1010	1	3	1	2	2	2	182	381	32	163	39	13	39	8426	5	2	2	2	1	1	2
64	90	1010	3	3	1	2	1	2	148	35	1	138	5	10	39	8426	5	1	1	2	1	1	2
51	100	1015	2	0	2	2	2	2	129	107	7	132	4.400	5	14	6300	5	1	2	2	1	1	1
67	70	1010	1	0	1	1	2	2	102	48	3	137	5	12	34	7100	4	1	1	2	1	1	2
70	80	1017	1	0	1	1	2	2	158	85	3	141	3.500	10	30	8426	5	1	2	2	1	1	2
56	80	1010	1	0	1	1	2	2	165	55	2	138	5	14	40	11800	5	1	1	2	2	1	2

Gambar 3. Dataset PGK

3.2 Neural Network

Setelah data dikumpulkan dan diproses, tahap selanjutnya dalam penelitian ini adalah pengembangan model NN. Model NN digunakan sebagai metode klasifikasi untuk diagnosis PGK berdasarkan variabel prediktor yang telah ditentukan sebelumnya. Neural Network yang digunakan dalam penelitian ini terdiri dari beberapa lapisan, termasuk lapisan input, lapisan tersembunyi, dan lapisan output. Untuk mengevaluasi performa model NN dalam mengklasifikasikan PGK dan non-PGK, digunakan matriks kebingungan. Gambar 4 menunjukkan hasil matriks kebingungan yang dihasilkan dari pengujian model NN pada data PGK.




Gambar 4. Matriks Kebingungan NN untuk Diagnosis PGK

Dari Gambar 4, dapat dilihat bahwa model berhasil mengklasifikasikan dengan baik antara pasien PGK dan non-PGK. Sebanyak 242 sampel pasien PGK diklasifikasikan dengan benar, sedangkan 150 sampel pasien non-PGK juga diklasifikasikan dengan benar. Hanya terdapat beberapa kesalahan pada klasifikasi dengan 8 sampel non-PGK diklasifikasikan sebagai PGK dan tidak ada sampel PGK yang salah diklasifikasikan sebagai non-PGK.

Matriks kebingungan ini memberikan gambaran mengenai akurasi model NN dalam menangani tugas klasifikasi PGK. Model menunjukkan kinerja yang baik dengan tingkat kesalahan yang rendah, yang menunjukkan bahwa model tersebut dapat diandalkan untuk diagnosis PGK.

Untuk memastikan performa yang baik dari model NN, digunakan analisis Receiver Operating Characteristic (ROC) dan Area Under the Curve (AUC). ROC digunakan untuk mengukur performa model dalam mendeteksi pasien dengan PGK dan non-PGK, dengan melihat keseimbangan antara sensitivitas (True Positive Rate) dan spesifisitas (False Positive Rate). AUC yang lebih tinggi menunjukkan model yang lebih baik dalam memprediksi hasil yang diinginkan. Gambar 5 menampilkan kurva ROC yang dihasilkan dari pengujian model NN.



Gambar 5. Kurva ROC untuk Neural Network dalam Klasifikasi PGK

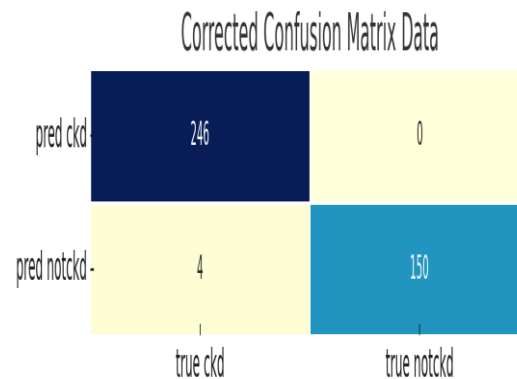
Berdasarkan Gambar 5, terlihat bahwa AUC yang dihasilkan adalah 0.999, yang menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antara pasien dengan PGK dan non-PGK. Kurva ROC menunjukkan bahwa model memiliki sensitivitas yang tinggi dengan tingkat kesalahan yang sangat rendah. Hal ini mengindikasikan bahwa NN mampu melakukan klasifikasi yang sangat akurat dalam diagnosis PGK, dengan hanya sedikit prediksi yang salah.

Selanjutnya, untuk meningkatkan performa model, penelitian ini mengimplementasikan algoritma PSO, yang bertujuan untuk mengoptimalkan parameter-parameter penting dalam NN, seperti learning rate, jumlah neuron, dan konfigurasi lapisan tersembunyi.

3.3 Particle Swarm Optimization

Setelah model NN dikembangkan, optimasi lebih lanjut dilakukan dengan menggunakan metode PSO. Dalam konteks ini, PSO digunakan untuk mengoptimalkan parameter-parameter dalam model NN, seperti jumlah *neuron* di lapisan tersembunyi dan *learning rate*, dengan tujuan untuk meningkatkan performa klasifikasi model.


Dengan menggunakan PSO, model NN yang telah dikembangkan sebelumnya dioptimalkan agar lebih efisien dan akurat dalam mendiagnosis PGK. PSO iteratif mencari parameter optimal dengan memperbarui posisi partikel dalam ruang solusi hingga mencapai konvergensi atau hasil terbaik. Hasil dari proses optimasi menggunakan PSO dapat dilihat pada matriks kebingungan Gambar 6.



Gambar 6. Matriks Kebingungan Setelah Penggunaan PSO

Dari Gambar 6, dapat dilihat bahwa setelah optimasi menggunakan PSO, hasil klasifikasi menjadi lebih akurat. Sebanyak 246 sampel pasien PGK diklasifikasikan dengan benar, sedangkan 150 sampel pasien non-PGK juga diklasifikasikan dengan benar. Hanya terdapat sedikit kesalahan, yaitu 4 sampel non-PGK yang salah diklasifikasikan sebagai PGK. Tidak ada sampel PGK yang salah diklasifikasikan sebagai non-PGK. Hasil ini menunjukkan bahwa PSO berhasil meningkatkan performa NN, membuat model lebih akurat dalam klasifikasi PGK dengan tingkat kesalahan yang lebih rendah. Hal ini membuktikan bahwa metode PSO efektif dalam mengoptimalkan parameter model untuk diagnosis yang lebih akurat.

Untuk memastikan performa yang baik dari model NN optimasi menggunakan PSO digunakan analisis ROC atau AUC. Gambar 7 menampilkan kurva ROC yang dihasilkan dari pengujian model NN.



Gambar 7. Kurva ROC Setelah Optimasi Menggunakan PSO



Meskipun optimasi menggunakan PSO telah diterapkan pada model NN, hasil analisis kurva ROC menunjukkan bahwa tidak ada perbedaan signifikan dalam performa model sebelum dan sesudah optimasi. Nilai AUC tetap mendekati 1, yang mengindikasikan bahwa model Neural Network sudah memiliki kemampuan yang sangat baik dalam membedakan antara pasien PGK dan non-PGK, bahkan tanpa proses optimasi lebih lanjut.

3.4 Evaluasi

Pada tahap evaluasi, dilakukan perbandingan performa antara model NN tanpa optimasi dan model NN yang telah dioptimasi menggunakan PSO. Evaluasi ini dilakukan berdasarkan beberapa metrik performa utama, yaitu akurasi, precision, recall, dan AUC. Hasil evaluasi performa kedua model ini ditampilkan pada Tabel 1:

Tabel 1. Evaluasi Perbandingan NN dan NN+PSO


Metode	NN	NN+PSO
Akurasi	98,00%	99,00%
Precision	95,15%	97,50%
Recall	100,00%	100,00%
AUC	99,90%	99,90%

Berdasarkan Tabel 1, dapat dilihat bahwa model NN yang dioptimasi dengan PSO menunjukkan sedikit peningkatan dalam hal akurasi dan *precision* dibandingkan dengan model NN tanpa optimasi. Akurasi model meningkat dari 98,00% menjadi 99,00%, dan *precision* meningkat dari 95,15% menjadi 97,50%. Namun, *recall* dan nilai AUC tetap sama di kedua model dengan *recall* mencapai 100,00% dan AUC sebesar 99,90%.

Ini menunjukkan bahwa meskipun PSO berhasil meningkatkan akurasi dan *precision*, performa keseluruhan model dalam mendeteksi PGK tetap sangat baik bahkan tanpa optimasi. Optimasi PSO memberikan manfaat tambahan dalam mengurangi tingkat kesalahan positif palsu (*false positives*), tetapi tidak terlalu berpengaruh pada kemampuan model untuk mendeteksi pasien dengan PGK (*recall*) atau pada nilai AUC.

3.5 Analisis dan Interpretasi Hasil

Setelah melakukan evaluasi terhadap performa model NN baik sebelum maupun sesudah optimasi menggunakan PSO, analisis lebih mendalam dilakukan terhadap struktur dan arsitektur model. Gambar berikut menampilkan arsitektur NN yang digunakan dalam penelitian ini



Gambar 8. Arsitektur Neural Network PGK

Neuron-neuron di lapisan tersembunyi berfungsi untuk mempelajari pola dari data, sedangkan lapisan output memberikan hasil klasifikasi apakah pasien didiagnosis dengan PGK atau tidak. Dalam neuron tersebut akan di optimalkan dengan metode PSO. Dalam proses ini, setiap variabel memiliki bobot yang berbeda berdasarkan pengaruhnya terhadap hasil prediksi, di mana bobot yang lebih tinggi menunjukkan bahwa variabel tersebut memiliki kontribusi yang lebih besar dalam proses klasifikasi. Dengan demikian, analisis bobot ini memberikan wawasan penting mengenai variabel-variabel yang paling berpengaruh dalam memprediksi PGK.

Setiap variabel memiliki bobot yang berbeda berdasarkan pengaruhnya terhadap hasil prediksi. Bobot yang lebih tinggi menunjukkan bahwa variabel tersebut memiliki kontribusi yang lebih besar dalam proses klasifikasi. Analisis ini memberikan wawasan penting mengenai variabel mana yang paling berpengaruh dalam memprediksi PGK. Gambar berikut menampilkan bobot atau pentingnya masing-masing variabel prediktor dalam model NN yang digunakan untuk klasifikasi PGK.



Attribute	Weight
age	0
bp	0
sg	1
al	1
su	0,275
rbc	0
pc	1
pcc	0
ba	1
bgr	0,624
bu	0
sc	1
sod	0
pot	0,659
hemo	1
pcv	0,920
wc	0,387
rc	0
htn	1
dm	0,365
cad	0
appet	0,0699
pe	1

Gambar 9. Bobot Variabel

Dari Gambar 9, dapat dilihat bahwa beberapa variabel memiliki bobot yang lebih signifikan dibandingkan dengan yang lain. Misalnya, variabel tertentu seperti sg (spesifik gravitasi urine) dan al (tingkat albumin dalam urine) memiliki bobot yang lebih tinggi, menunjukkan bahwa variabel-variabel ini sangat penting dalam menentukan apakah seorang pasien mengalami PGK. Sebaliknya, variabel dengan bobot yang lebih rendah mungkin memiliki kontribusi yang lebih kecil terhadap keputusan klasifikasi.

Interpretasi hasil ini memungkinkan peneliti untuk lebih memahami karakteristik medis yang paling kritis dalam diagnosis PGK, serta memberikan wawasan untuk pengembangan model di masa depan.

4 KESIMPULAN

Hasil menunjukkan bahwa optimasi menggunakan PSO memberikan peningkatan yang signifikan dalam akurasi dan precision, meskipun tidak mengubah nilai recall dan AUC. PSO efektif dalam mengurangi kesalahan prediksi positif palsu (false positives) tanpa mengorbankan recall dan kemampuan model dalam mendeteksi PGK secara akurat. Secara keseluruhan, penggunaan PSO sebagai metode optimasi terbukti meningkatkan performa Neural Network dalam beberapa aspek, terutama dalam hal precision dan akurasi, dengan hasil yang sangat baik dalam diagnosis PGK. Penelitian ini juga mengungkapkan bahwa

beberapa variabel prediktor seperti spesifik gravitasi urine (sg) dan tingkat albumin dalam urine (al) memiliki kontribusi yang signifikan dalam proses klasifikasi. Analisis ini membantu memperjelas pentingnya variabel-variabel tersebut dalam diagnosis PGK, yang dapat menjadi panduan bagi pengembangan model prediktif di masa depan.

Saran untuk riset lanjutan penggunaan dataset yang lebih besar dan beragam, serta mengeksplorasi kombinasi metode optimasi yang lain. Penelitian lanjutan dapat semakin memperkuat kontribusi metode kecerdasan buatan dalam diagnosis dan pengelolaan PGK, serta memberikan dampak yang signifikan dalam upaya peningkatan kualitas perawatan kesehatan.

5 REFERENCE

A, R., S, S. P., Rangarao, K. V., & Saranya, A. (2019). Efficient datamining model for prediction of chronic kidney disease using wrapper methods. *International Journal of Informatics and Communication Technology (IJ-ICT)*, 8(2), 63. <https://doi.org/10.11591/ijict.v8i2.pp63-70>

Akben, S. B. (2019). Early Stage Chronic Kidney Disease Diagnosis by Applying Data Mining Methods to Urinalysis, Blood Analysis and Disease History. *Irbm*, 39(5), 353–358. <https://doi.org/10.1016/j.irbm.2018.09.004>

Alaiad, A., Najadat, H., Mohsen, B., & Balhaf, K. (2020). Classification and Association Rule Mining Technique for Predicting Chronic Kidney Disease. *Journal of Information and Knowledge Management*, 19(1). <https://doi.org/10.1142/S0219649220400158>

Arif-Ul-Islam, & Ripon, S. H. (2019). Rule Induction and Prediction of Chronic Kidney Disease Using Boosting Classifiers, Ant-Miner and J48 Decision Tree. *2nd International Conference on Electrical, Computer and Communication Engineering, ECCE 2019*, 1–6. <https://doi.org/10.1109/ECACE.2019.8679388>

Chittora, P., Chaurasia, S., Chakrabarti, P., Kumawat, G., Chakrabarti, T., Leonowicz, Z., ... Bolshev, V. (2021). Prediction of Chronic Kidney Disease - A Machine Learning Perspective. *IEEE Access*, 9, 17312–17334. <https://doi.org/10.1109/ACCESS.2021.30>



- 53763
- Elhoseny, M., Shankar, K., & Uthayakumar, J. (2019). Intelligent Diagnostic Prediction and Classification System for Chronic Kidney Disease. *Scientific Reports*, 9(1), 1–14. <https://doi.org/10.1038/s41598-019-46074-2>
- Hosseinzadeh, M., Koohpayehzadeh, J., Bali, A. O., Asghari, P., Souri, A., Mazaherinezhad, A., ... Rawassizadeh, R. (2021). A diagnostic prediction model for chronic kidney disease in internet of things platform. *Multimedia Tools and Applications*, 80(11), 16933–16950. <https://doi.org/10.1007/s11042-020-09049-4>
- Nurdin, H., Suhardjono, Wuryanto, A., Yuliandari, D., & Sugiarto, H. (2024). Naive Bayes and Particle Swarm Optimization in Early Detection Of Chronic Kidney Disease. *Jurnal Teknik Informatika (JUTIF)*, 5(3), 703–708. <https://doi.org/https://doi.org/10.52436/1.jutif.2024.5.3.1750>
- Pramanik, R., Khare, S., & Gourisaria, M. K. (2021). Inferring the Occurrence of Chronic Kidney Failure: A Data Mining Solution. *Proceedings of Second Doctoral Symposium on Computational Intelligence*. https://doi.org/https://doi.org/10.1007/978-981-16-3346-1_59
- Purwaningsih, E. (2022). Improving the Performance of Support Vector Machine With Forward Selection for Prediction of Chronic Kidney Disease. *JITK (Jurnal Ilmu Pengetahuan Dan Teknologi Komputer)*, 8(1), 18–24. <https://doi.org/10.33480/jitk.v8i1.3327>
- Qin, J., Chen, L., Liu, Y., Liu, C., Feng, C., & Chen, B. (2020). A machine learning methodology for diagnosing chronic kidney disease. *IEEE Access*, 8, 20991–21002. <https://doi.org/10.1109/ACCESS.2019.2963053>
- Rady, E. H. A., & Anwar, A. S. (2019). Prediction of kidney disease stages using data mining algorithms. *Informatika in Medicine Unlocked*, 15(December 2019), 100178. <https://doi.org/10.1016/j.imu.2019.100178>
- Revathy, S., Bharathi, B., Jeyanthi, P., & Ramesh, M. (2019). Chronic kidney disease prediction using machine learning models. *International Journal of Engineering and Advanced Technology*, 9(1), 6364–6367. <https://doi.org/10.35940/ijeat.A2213.109119>
- Saha, I., Gourisaria, M. K., & Harshvardhan, G. M. (2022). Classification System for Prediction of Chronic Kidney Disease Using Data Mining Techniques. *Lecture Notes in Networks and Systems*, 318(May 2017), 429–443. https://doi.org/10.1007/978-981-16-5689-7_38
- Senan, E. M., Al-Adhaileh, M. H., Alsaade, F. W., Aldhyani, T. H. H., Alqarni, A. A., Alsharif, N., ... Alzahrani, M. Y. (2021). Diagnosis of Chronic Kidney Disease Using Effective Classification AlgoSaha, I., Gourisaria, M. K., & Harshvardhan, G. M. (2022). Classification System for Prediction of Chronic Kidney Disease Using Data Mining Techniques. *Advances in Data and Information. Journal of Healthcare Engineering*, 2021. <https://doi.org/10.1155/2021/1004767>
- Widiati, W., Iriadi, N., Ariyati, I., Nawawi, I., & Sugiono. (2024). Pendekatan Hibrida Decision Tree-Particle Swarm Optimization untuk Deteksi Dini Penyakit Ginjal Kronis. *JASIEK (Jurnal Aplikasi Sains, Informasi, Elektronika Dan Komputer)*, 6(1), 11–21. <https://doi.org/10.26905/jasiek.v6i1.13006>
- Widodo, S., Brawijaya, H., & Samudi, S. (2024). Building a Predictive Model for Chronic Kidney Disease: Integrating KNN and PSO. *Paradigma - Jurnal Komputer Dan Informatika*, 26(1), 58–64. <https://doi.org/10.31294/p.v26i1.3282>
- Wijaya, G. (2024). Improvement of Kernel SVM to Enhance Accuracy in Chronic Kidney Disease. 9(1), 136–144. <https://doi.org/https://doi.org/10.33395/sin-kron.v9i1.13112> e-ISSN