

PENDEKATAN ALGORITMA NEURAL NETWORK DAN GENETIC ALGORITHM UNTUK PREDIKSI PENYAKIT GINJAL KRONIS

Hendy D. Siswaja¹, Yudi Ramdhani²

¹SATU University
e-mail: hendy.siswaja@univ.satu.ac.id

²SATU University
e-mail: yudi.ramdhani@univ.satu.ac.id

Abstract

Chronic kidney disease (CKD) is a global public health issue affecting around 10% of the world's population. The prevalence of CKD in China is 10.8%, with a prevalence range of 10%-15% in the United States. With the development of Artificial Intelligence (AI), where Machine Learning (ML) is a subset of AI, this study attempts to utilize Neural Network algorithms, data optimization based on Genetic Algorithm, and k-fold Cross Validation with k values of 10, 20, 30, 40, and 50 to predict whether a patient has CKD based on a dataset containing the patient's clinical test results. The results of this study reveal that the Neural Network algorithm with GA-based data optimization can achieve an accuracy rate of up to 98.75% and an AUC value of 0.999. Therefore, it can be concluded that the Neural Network algorithm with GA-based optimization can be further developed into an application or part of a healthcare system, enabling faster diagnosis of CKD with high accuracy and improving the chances of recovery for the patient.

Keywords: *Chronic Kidney Disease, Machine Learning, Neural Network, Genetic Algorithm, Cross Validation*

Abstrak

Penyakit ginjal kronis (PGK) merupakan masalah kesehatan masyarakat global yang mempengaruhi sekitar 10% dari populasi dunia. Persentase prevalensi PGK di China adalah 10,8%, dan rentang prevalensinya adalah 10%-15% di Amerika Serikat. Seiring dengan perkembangan *Artificial Intelligence (AI)* dimana *Machine Learning (ML)* merupakan subbagian dari AI, penelitian ini mencoba memanfaatkan algoritma Neural Network, optimasi data berbasis *Genetic Algorithm*, dan *k-fold Cross Validation* dengan nilai k berkelipatan 10, yaitu 10, 20, 30, 40, dan 50 untuk memprediksi apakah seorang pasien mengidap PGK atau tidak dari dataset yang berisi hasil uji klinis pasien tersebut. Hasil penelitian ini mengungkapkan bahwa algoritma *Neural Network* dengan optimasi data berbasis GA mampu memperoleh tingkat akurasi sampai dengan 98,75% dan nilai AUC sebesar 0,999 sehingga dapat disimpulkan bahwa algoritma *Neural Network* dengan optimasi berbasis GA ini dapat dikembangkan lebih lanjut menjadi sebuah aplikasi ataupun bagian dari sistem kesehatan sehingga tingkat diagnosa pasien yang mengidap PGK dapat lebih cepat dilakukan dengan tingkat akurasi yang tinggi dan dapat meningkatkan peluang kesembuhan bagi pasien tersebut.

Keywords: *Chronic Kidney Disease, Machine Learning, Neural Network, Genetic Algorithm, Cross Validation*

1. Pendahuluan

Ginjal merupakan organ yang sangat penting dalam mengatur jumlah air dan mineral dalam darah serta menjaga stabilitas internal tubuh. Ketidaknormalan yang terjadi di organ ginjal dapat berdampak negatif pada

bagian tubuh lainnya (Qezelbash-Chamak et al., 2022). Penyakit Ginjal Kronis (PGK) adalah kondisi dimana ginjal Anda mengalami kerusakan dan tidak dapat menyaring darah seperti seharusnya. Peran utama ginjal adalah menyaring kelebihan air

dan limbah dalam darah untuk menghasilkan urine, dan jika seseorang mengidap PGK, ini berarti bahwa limbah akan tertimbun di dalam tubuh. Penyakit ini bersifat kronis karena kerusakan terjadi secara bertahap selama periode yang lama. PGK dapat menyebabkan berbagai masalah kesehatan dan ada banyak penyebab PGK seperti diabetes, tekanan darah tinggi, dan penyakit jantung. Selain penyakit-penyakit kritis tersebut, PGK juga bergantung pada usia dan jenis kelamin. Jika ginjal Anda tidak berfungsi, Anda mungkin akan merasakan satu atau lebih gejala seperti nyeri perut, nyeri punggung, diare, demam, mimisan, ruam kulit, dan muntah. Ada dua penyakit utama yang muncul dari PGK yaitu, diabetes dan tekanan darah tinggi. Oleh karena itu, pengendalian kedua penyakit ini merupakan langkah pencegahan PGK. Menurut penelitian, kasus rawat inap PGK meningkat 6,23% per tahun tetapi angka kematian global tetap stabil. Ada beberapa tes diagnostik untuk memeriksa kondisi PGK yaitu laju filtrasi glomerulus perkiraan (eGFR), tes urine, dan tekanan darah (Chittora et al., 2021).

Penyakit ginjal kronis (PGK) merupakan masalah kesehatan masyarakat global yang mempengaruhi sekitar 10% dari populasi dunia. Persentase prevalensi PGK di China adalah 10,8%, dan rentang prevalensinya adalah 10%-15% di Amerika Serikat. Menurut studi lain, persentase ini telah mencapai 14,7% pada populasi umum dewasa di Meksiko. Penyakit ini ditandai dengan penurunan fungsi ginjal yang lambat, yang pada akhirnya menyebabkan kehilangan fungsi ginjal secara total. PGK tidak menunjukkan gejala yang jelas pada tahap awalnya. Oleh karena itu, penyakit ini mungkin tidak terdeteksi sampai ginjal kehilangan sekitar 25% fungsinya (Qin et al., 2019). Penurunan fungsi ginjal yang bertahap dapat menyebabkan *End State Kidney Disease* (ESKD) pada pasien PGK, mempercepat kebutuhan akan *Kidney Replacement Therapy* (KRT). Intervensi tepat waktu pada pasien PGK yang memiliki resiko tinggi untuk ESKD tidak hanya dapat meningkatkan kualitas hidup pasien dengan menunda progresi penyakit, tetapi juga mengurangi morbiditas, mortalitas, dan biaya perawatan kesehatan yang timbul akibat KRT. Karena progresi penyakit biasanya tidak menimbulkan gejala, model prediksi yang dapat diandalkan untuk resiko ESKD pada tahap awal PGK dapat menjadi penting

secara klinis. Model tersebut diharapkan dapat membantu dokter dalam membuat keputusan pengobatan yang dipersonalisasi untuk pasien berisiko tinggi, sehingga meningkatkan prognosis secara keseluruhan dan mengurangi beban ekonomi dari penyakit ini (Bai et al., 2022).

Saat ini, *Machine Learning* (ML) yang merupakan subdomain dari *Artificial Intelligence* (AI) menjadi salah satu teknologi yang paling mencolok dan sukses di industri medis untuk mendiagnosis dan memprediksi berbagai penyakit beserta tahapannya karena ML berkaitan dengan eksplorasi *dataset* besar dan pola, fitur, modus, dan lain-lain. *Dataset* berbagai penyakit dapat dimasukkan ke dalam algoritma-algoritma ini dengan tujuan mengembangkan model pembelajaran mesin. Pengenalan algoritma dalam basis data medis akan sangat membantu para profesional medis dalam membuat keputusan yang terinformasi tentang penyakit, mencegah kesalahan, dan memberikan kehidupan yang aman bagi masyarakat umum (Nishat et al., 2021).

Salah satu algoritma dalam ML adalah algoritma *Neural Network* (NN) yang mana algoritma ini digunakan dalam penelitian ini. Model ini merupakan representasi yang disederhanakan dari sistem saraf nyata. Tujuannya adalah untuk menangkap karakteristik utama yang penting dalam fungsi pemrosesan informasi dari jaringan nyata tanpa terlalu memperhatikan batasan fisik yang diberlakukan oleh biologi. Jaringan saraf tiruan terdiri dari unit pemrosesan sederhana yang sangat terhubung yang disebut *neuron*, masing-masing melakukan dua fungsi, yaitu, penggabungan inputnya dari neuron lain atau lingkungan eksternal dan menghasilkan output dari input yang tergabung tersebut. Melalui struktur yang sederhana ini, neural network telah terbukti mampu mendekati sebagian besar fungsi kontinu dengan tingkat akurasi tinggi, dengan memilih jumlah unit *neuron* yang sesuai (Dongare et al., 2012).

Dalam ML juga, dapat dilakukan optimasi data yang akan meningkatkan hasil dari pemrosesan data. Penelitian ini menggunakan optimasi yang berdasarkan *Genetic Algorithm* (GA). GA terinspirasi dari teori evolusi yang menjelaskan munculnya spesies. Di lingkungan alam, spesies yang lebih lemah dan kurang cocok menghadapi kepunahan karena seleksi alam. Yang lebih kuat memiliki peluang lebih besar untuk mewariskan materi genetik mereka kepada

generasi mendatang melalui reproduksi. Seiring berjalannya waktu, spesies dengan kombinasi genetik yang menguntungkan menjadi dominan dalam populasi mereka (Konak et al., 2006).

Dari fakta bahwa PGK adalah salah satu masalah kesehatan global seperti yang telah dijelaskan sebelumnya dan bagaimana ML dapat membantu melakukan analisa dan prediksi dari dataset yang diberikan, penelitian ini bertujuan untuk memanfaatkan ML dengan menggunakan algoritma NN dan optimasi data berbasis GA untuk melakukan prediksi terhadap kemungkinan seorang pasien menderita PGK berdasarkan data hasil uji klinis yang tersedia. Dari hasil penelitian ini diharapkan analisa dan prediksi terhadap PGK dapat lebih cepat dilakukan dengan bantuan ML sehingga peluang yang dimiliki oleh seorang pasien untuk sembuh menjadi lebih tinggi.

Penelitian terkait PGK dengan memanfaatkan algoritma Neural Network ini sudah pernah dilakukan oleh Sirshendu Hore, Sankhadeep Chatterjee, Rahul Kr. Shaw, Nilanjan Dey and Jitendra Virmani dalam jurnal yang berjudul *Detection of Chronic Kidney Disease: A NN-GA-Based Approach* yang diterbitkan pada Nature Inspired Computing, Advances in Intelligent Systems and Computing 652, pada tahun 2018 dengan abstrak sebagai berikut : Dalam penelitian ini, sebuah model berbasis *Neural Network* (NN) yang dilatih dengan *Genetic Algorithm* (GA) telah diusulkan untuk mendeteksi penyakit ginjal kronis (PGK) yang telah menjadi salah satu ancaman terbaru bagi negara-negara berkembang dan belum berkembang. Studi dan survei di berbagai wilayah India telah menunjukkan bahwa PGK menjadi perhatian utama dari hari ke hari. Beban keuangan dari pengobatan dan konsekuensi masa depan dari PGK bisa menjadi tidak terjangkau bagi banyak orang, jika tidak terdeteksi pada tahap awal. Dalam semangat ini, model NN-GA telah diusulkan yang secara signifikan mengatasi masalah penggunaan algoritma pembelajaran berbasis pencarian lokal untuk melatih NN. Vektor bobot input dari NN secara bertahap dioptimalkan dengan menggunakan GA untuk melatih NN. Model tersebut telah dibandingkan dengan klasifikasi terkenal seperti *Random Forest*, *Multilayer Perception Feedforward Network* (MLP-FFN), dan juga dengan NN. Kinerja klasifikasi diukur dalam hal akurasi, presisi, recall, dan *F-Measure*. Hasil eksperimental menunjukkan bahwa

model berbasis NN-GA mampu mendeteksi PGK secara lebih efisien daripada model yang ada sebelumnya (Hore et al., 2018).

Penelitian lain juga pernah dilakukan oleh Vijendra Singh, Vijayan K. Asari, dan Rajkumar Rajasekaran dalam jurnal yang berjudul *A Deep Neural Network for Early Detection and Prediction of Chronic Kidney Disease* yang diterbitkan pada jurnal Diagnostic, pada tahun 2022 dengan abstrak sebagai berikut : Diabetes dan tekanan darah tinggi adalah penyebab utama Penyakit Ginjal Kronis (PGK). Tingkat Filtrasi Glomerulus (GFR) dan penanda kerusakan ginjal digunakan oleh para peneliti di seluruh dunia untuk mengidentifikasi PGK sebagai kondisi yang menyebabkan penurunan fungsi ginjal seiring waktu. Seseorang dengan PGK memiliki peluang lebih tinggi untuk meninggal muda. Dokter menghadapi tugas sulit dalam mendiagnosis berbagai penyakit yang terkait dengan PGK pada tahap awal untuk mencegah penyakit ini. Penelitian ini memperkenalkan model *deep learning* baru untuk deteksi dini dan prediksi PGK. Tujuan penelitian ini adalah membuat jaringan saraf dalam dan membandingkan kinerjanya dengan teknik machine learning kontemporer lainnya. Dalam uji coba, rata-rata dari fitur yang terkait digunakan untuk menggantikan semua nilai yang hilang dalam basis data. Setelah itu, parameter optimal jaringan saraf ditetapkan dengan menentukan parameter dan menjalankan beberapa uji coba. Fitur-fitur terpenting dipilih dengan Eliminasi Fitur Rekursif (RFE). Hemoglobin, Gravitasi Spesifik, Kreatinin Serum, Jumlah Sel Darah Merah, Albumin, Volume Sel Terbungkus, dan Hipertensi ditemukan sebagai fitur utama dalam RFE. Fitur-fitur yang terpilih dimasukkan ke dalam model *machine learning* untuk tujuan klasifikasi. Model *deep neural* yang diusulkan mengungguli empat *classifier* lainnya (*Support Vector Machine* (SVM), *K-Nearest Neighbor* (KNN), regresi logistik, *Random Forest*, dan *classifier Naive Bayes*) dengan mencapai akurasi 100%. Pendekatan yang diusulkan dapat menjadi alat yang berguna bagi nephrologist dalam mendeteksi PGK (Singh et al., 2022).

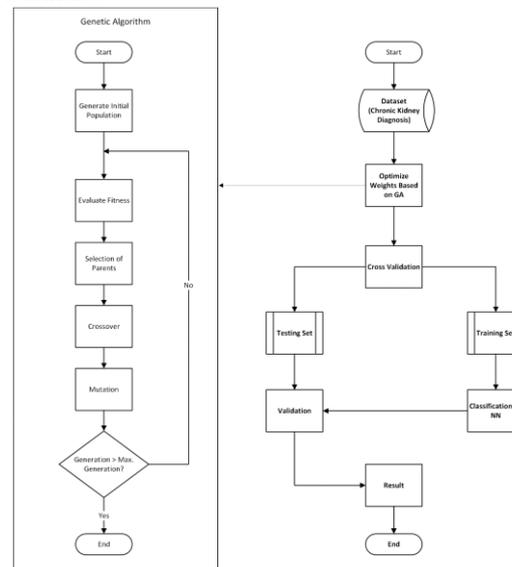
Penelitian yang terkait prediksi PGK juga telah dilakukan oleh Njoud Abdullah Almansour, Hajra Fahim Syed, Nuha Radwan Khayat, Rawan Kanaan Altheeb, Renad Emad Juri, Jamal Alhiyafi, Saleh Alrashed, Sunday O. Olatunji dalam jurnal yang berjudul *Neural network and support vector machine for the prediction of chronic*

kidney disease: A comparative study yang diterbitkan pada jurnal *Computers in Biology and Medicine* pada tahun 2019 dengan abstrak sebagai berikut : Makalah ini bertujuan untuk membantu dalam pencegahan Penyakit Ginjal Kronis (PGK) dengan memanfaatkan teknik *machine learning* untuk mendiagnosis PGK pada tahap awal. Penyakit ginjal adalah gangguan yang mengganggu fungsi normal ginjal. Seiring dengan meningkatnya persentase pasien yang terkena PGK, prosedur prediksi yang efektif harus dipertimbangkan. Dalam makalah ini, kami fokus pada penerapan berbagai algoritma klasifikasi *machine learning* pada *dataset* yang terdiri dari 400 pasien dan 24 atribut yang terkait dengan diagnosis penyakit ginjal kronis. Teknik klasifikasi yang digunakan dalam studi ini meliputi Jaringan Saraf Tiruan (ANN) dan Mesin Vektor Pendukung (SVM). Untuk melakukan eksperimen, semua nilai yang hilang dalam *dataset* diganti dengan rata-rata atribut yang sesuai. Kemudian, parameter yang dioptimalkan untuk teknik Jaringan Saraf Tiruan (ANN) dan Mesin Vektor Pendukung (SVM) ditentukan dengan menyetel parameter dan melakukan beberapa eksperimen. Model akhir dari dua teknik yang diusulkan dikembangkan menggunakan parameter dan fitur terbaik yang diperoleh. Hasil empiris dari eksperimen menunjukkan bahwa ANN berkinerja lebih baik daripada SVM, dengan akurasi masing-masing sebesar 99,75% dan 97,75%, yang menunjukkan bahwa hasil studi ini sangat menjanjikan (Almansour et al., 2019).

Dari penelitian-penelitian yang telah dilakukan sebelumnya, dapat dilihat bahwa banyak yang telah berusaha untuk melakukan pendekatan ML untuk membantu diagnosa PGK dengan tujuan utama yang sama, yaitu mempercepat proses diagnosa pasien sehingga meningkatkan peluang sembuh bagi pasien. Dalam penelitian ini, algoritma NN dengan optimasi GA pada *dataset* digunakan untuk memperoleh hasil yang terbaik. Dalam penelitian ini juga, dipergunakan *k-fold Cross Validation* dengan nilai *k* merupakan kelipatan 10, yaitu 10, 20, 30, 40, dan 50. Dengan menggunakan *cross validation*, kita mendapatkan gambaran yang lebih baik tentang bagaimana model akan bekerja pada data yang tidak terlihat, yang sangat penting untuk memastikan model tersebut memiliki kinerja yang baik di lingkungan nyata.

2. Metode Penelitian

Dalam penelitian ini, dipergunakan proses klasifikasi dengan menggunakan algoritma *Neural Network* dengan menambahkan optimasi algoritma genetik untuk meningkatkan nilai akurasi dari *dataset* sebagai sumber data yang dapat digambarkan melalui alur proses sebagai berikut :



Gambar 1. Alur proses algoritma NN dan optimasi GA

Dari gambar alur proses diatas, dapat dijelaskan sebagai berikut :

A. Dataset

Sebuah *dataset* terkadang dianggap terdiri dari data yang terkait oleh waktu, tempat, instrumen, atau objek pengamatan (Renear et al., 2010). *Dataset* ini merupakan kumpulan data dari diagnosa ginjal kronik yang nantinya akan digunakan sebagai data latih sekaligus data tes untuk digunakan oleh algoritma. *Dataset* berasal dari UCI Machine Learning Repository dimana tujuan dari *dataset* ini adalah untuk memprediksi secara diagnostik apakah seorang pasien terserang penyakit ginjal kronik atau tidak berdasarkan pengukuran nilai diagnostik yang tersedia. *Dataset* ini terdiri dari 14 kolom atribut medis dan 400 baris data serta *dataset* ini tidak memiliki data kosong (*null*) dengan rincian kolom sebagai berikut :

Table 1. Daftar Kolom Atribut Medis Pada Dataset

Kolom	Keterangan
BP	Blood Pressure (Tekanan Darah)
SG	Specific Gravity (Masa jenis urine)
AI	Albumin (Protein dalam darah)

Su	Sugar (Gula Darah)
Rbc	Red Blood Cell (Sel Darah Merah)
Bu	Blood Urea (Ureum)
Sc	Serum Creatinine (Kreatinin)
Sod	Sodium
Pot	Potassium
Hemo	Hemoglobin
Wbcc	White Blood Cell Count (Jumlah sel darah putih)
Rbcc	Red Blood Cell Count (Jumlah sel darah merah)
Htn	Hypertension
Class	Diagnosa penyakit

B. Genetic Algorithm

GA terinspirasi oleh evolusi biologis. Mutasi dan *crossover* adalah dua operator GA yang paling sering digunakan. Mutasi bekerja pada satu solusi dan umumnya mengubah fitur secara acak atau berdasarkan beberapa kriteria yang telah ditentukan sebelumnya. *Crossover*, di sisi lain, menggunakan dua solusi induk untuk menghasilkan dua keturunan, menghasilkan solusi baru dan yang telah diperbaiki (Ahmed et al., 2020). Secara umum, model matematis didasarkan pada populasi awal kromosom yang terdiri dari n individu. Ada tiga operasi dalam setiap iterasi dari sejumlah maksimum t epoch: reproduksi, mutasi, dan seleksi. Individu terbaik yang dievaluasi oleh fungsi kebugaran dianggap sebagai solusi untuk masalah yang diberikan pada akhir algoritma (Polap, 2020). Dari diagram yang ditampilkan di gambar 1 diatas, ada siklus yang dilakukan oleh GA untuk mendapatkan hasil optimisasi. *Dataset* kemudian akan dioptimasi terlebih dahulu dengan menggunakan GA untuk meningkatkan akurasi hasil. Adapun nilai parameter yang digunakan dalam penelitian ini adalah sebagai berikut :

Table 2. Nilai Parameter GA

Parameter	Value
Maximum Number of Generation	30
Population Size	5
Crossover	Uniform
Selection	Tournament

C. Cross Validation

Data dari *dataset* yang tersedia, berikutnya akan dilakukan *cross validation*. Teknik ini biasanya digunakan dalam konteks di mana hasil prediksi diproyeksikan, dan digunakan untuk menilai akurasi model prediktif secara praktis. Dalam ML, terdapat dua subset utama dari *cross validation* : yang menyeluruh dan yang tidak menyeluruh. Metode *cross validation* yang menyeluruh mencoba dan menguji semua kemungkinan cara untuk membagi sampel asli menjadi set

pelatihan dan validasi, seperti *Leave-P-Out* dan *Leave-one-out Cross-Validation*. Yang tidak menyeluruh mencakup *Hold-out* dan *K-fold* (Seraj et al., 2023). Dalam penelitian ini, yang akan digunakan adalah *k-fold Cross Validation* seperti yang telah dijelaskan di bab sebelumnya tujuan dari jumlah *k-folds* ini adalah untuk mencoba menemukan kemungkinan yang dapat berpengaruh terhadap hasil testing. Dari hasil *cross validation*, data akan dijadikan dua jenis yaitu *Training Set* dan *Testing Set* dimana *Training Set* akan dipergunakan untuk melatih algoritma agar dapat mendapat hasil yang sesuai dan *Testing Set* adalah data yang akan digunakan untuk menguji algoritma terhadap hasil yang diharapkan.

D. Neural Network

Dalam proses ini, *Training Set* akan digunakan untuk melatih algoritma *Neural Network* (NN) yang juga telah ditambahkan optimasi data berdasarkan algoritma genetik agar dapat mendapatkan hasil yang terbaik dan mendekati hasil sebenarnya. Algoritma NN memproses *training set* melalui beberapa tahap yang melibatkan *forward propagation*, *backward propagation*, dan pembaruan bobot. Seluruh proses ini diulang sampai model mencapai kinerja yang memuaskan atau mencapai jumlah epoch yang telah ditentukan. Proses ini memungkinkan *neural network* untuk belajar dari data *training* dan membuat prediksi yang akurat pada data baru.

E. Validation

Dalam proses ini, *Testing Set* akan diuji dengan menggunakan algoritma NN yang telah dilatih sebelumnya untuk memperoleh hasil yang diharapkan. Hasil dari algoritma NN akan dievaluasi dengan memperhatikan dua hal yaitu, *Accuracy* dan AUC. *Accuracy* adalah ukuran evaluasi yang paling sederhana dan intuitif untuk sebuah klasifier (Japkowicz, 2006). AUC (*area under the curve*) dari kurva ROC (*Receiver Operating Characteristics*) baru-baru ini dimanfaatkan sebagai pengukuran alternatif untuk algoritma dalam ML. Kurva ROC membandingkan kinerja klasifikasi melintasi seluruh rentang distribusi kelas dan *error cost* (Ling et al., 2003). Adapun klasifikasi dari *Accuracy* dan AUC dapat dijabarkan sebagai berikut :

Tabel 3. Klasifikasi Nilai AUC

Performa	Klasifikasi
----------	-------------

0,90 – 1,00	Paling Baik
0,80 – 0,90	Baik
0,70 – 0,80	Cukup
0,60 – 0,70	Rendah
< 0,60	Gagal

F. Result

Pada proses ini, dilakukan uji *t-Test* untuk melihat signifikansi dari hasil akurasi sebelum dan setelah dilakukan optimasi berbasis GA pada data. *T-Test* digunakan untuk membandingkan rata-rata antara dua kelompok dan tidak memerlukan perbandingan ganda karena *P-value* yang unik diamati (Mishra et al., 2019). *P-value* merupakan probabilitas maksimum untuk mendapatkan hasil yang diamati secara kebetulan. Dalam berbagai jenis tes, termasuk tes laboratorium, skrining, atau diagnosis klinis, ada kemungkinan hasil positif palsu. Penentuan seberapa besar kesalahan yang dapat diterima biasanya menjadi tanggung jawab para ahli dalam bidang tersebut. Dalam konteks tes statistik, batas kesalahan ini telah diatur sebesar kurang dari 5% (0.05), dan nilai ambang batas untuk kesalahan yang dapat diterima dikenal sebagai *P-value* (Sil et al., 2019).

3. Hasil dan Pembahasan

Penelitian diawali dengan melakukan pemrosesan *dataset* tanpa optimasi dengan menggunakan algoritma *Decision Tree*, *Naïve Bayes*, *Neural Network*, dan *k-NN*. Tujuannya adalah untuk menemukan algoritma yang dapat memberikan hasil terbaik sebelum dilakukan optimasi. Hasil dari pemrosesan awal ini adalah sebagai berikut :

Tabel 4a. Hasil Pemrosesan *Machine Learning* (Bagian I)

CV	Decision Tree		Naïve Bayes	
	Accuracy	AUC	Accuracy	AUC
k = 10	96,25%	0,970	92,25%	0,994
k = 20	96,50%	0,966	92,25%	0,993
k = 30	96,75%	0,970	92,25%	0,993
k = 40	96,50%	0,964	92,25%	0,997
k = 50	96,50%	0,965	92,25%	0,995
Avg	96,50%	0,967	92,25%	0,994

Tabel 4b. Hasil Pemrosesan *Machine Learning* (Bagian II)

CV	k-NN		Neural Network	
	Accuracy	AUC	Accuracy	AUC
k = 10	70,00%	0,751	97,25%	0,998
k = 20	72,25%	0,763	97,50%	0,997
k = 30	71,96%	0,775	97,25%	1
k = 40	72,00%	0,773	98,25%	0,996
k = 50	72,00%	0,763	97,25%	0,996
Avg	71,64%	0,765	97,50%	0,997

Berdasarkan hasil pemrosesan sebagaimana yang disajikan di tabel-tabel diatas, dapat ditarik kesimpulan bahwa algoritma yang memberikan hasil terbaik adalah algoritma *Neural Network* di posisi pertama dengan capaian akurasi tertinggi di 98,25%, diikuti oleh algoritma *Decision Tree* dengan capaian akurasi tertinggi di 96,75%. Hasil ini sejalan dengan penelitian sebelumnya bahwa algoritma *Neural Network* adalah algoritma yang terbaik untuk melakukan prediksi pada kasus penyakit ginjal kronik.

Setelah menemukan algoritma yang terbaik untuk memproses *dataset*, langkah berikutnya dalam penelitian ini adalah dilakukannya optimasi dengan bantuan GA untuk mendapatkan hasil yang lebih baik lagi. Optimasi yang coba dilakukan adalah optimasi bobot dan menerapkannya ke algoritma *Neural Network* kembali. Hasil yang diperoleh dengan optimasi adalah sebagai berikut :

Tabel 5. Perbandingan Hasil NN dan Optimasi GA

CV	Neural Network		NN + GA	
	Accuracy	AUC	Accuracy	AUC
k = 10	97,25%	0,998	98,50%	0,999
k = 20	97,50%	0,997	98,25%	0,997
k = 30	97,25%	1,000	98,72%	0,999
k = 40	98,25%	0,996	98,25%	0,998
k = 50	97,25%	0,996	98,75%	0,999
Avg.	97,50%	0,9974	98,49%	0,9984

Dari data yang ditunjukkan pada tabel 5, terjadi peningkatan persentase akurasi dimana persentase tertingginya adalah 98.75% dengan nilai AUC sebesar 0,999. Sebelum dilakukan optimasi berbasis GA pada *dataset*, rata-rata tingkat akurasi dari hasil algoritma NN adalah 97,50% dengan rata-rata nilai AUC adalah 0,9974. Setelah dilakukan optimasi berbasis GA pada *dataset*, terjadi peningkatan rata-rata akurasi menjadi 98,49% dengan rata-rata nilai AUC adalah 0,9984. Berdasarkan rata-rata akurasi yang ada, terjadi peningkatan sebesar 0,99% dan untuk membuktikan signifikansi dari kenaikan persentase akurasi setelah dilakukan optimasi, pada penelitian ini dilakukan juga analisis *t-Test* dengan membandingkan hasil akurasi pemrosesan algoritma *Neural Network*, sebelum dan setelah dilakukan optimasi dengan hasil sebagai berikut :

Tabel 6. Hasil T-TEST Sebelum Dan Setelah Optimasi

t-Test: Paired Two Sample for Means		
	Variable 1	Variable 2
Mean	0,975	0,98494
Variance	0,00001875	5,89E-06
Observations	5	5
Pearson Correlation	-0,725389043	
Hypothesized Mean Difference	0	
df	4	
t Stat	-3,519030558	
P(T<=t) one-tail	0,012235728	
t Critical one-tail	2,131846786	
P(T<=t) two-tail	0,024471455	
t Critical two-tail	2,776445105	

Berdasarkan standar *P-value* tersebut, dapat dilihat di tabel 6, bahwa hasil *P-value* dari hasil *t-Test* baik *one-tail* maupun *two-tail* adalah sebesar 0,01 dan 0,02 yang berarti masih dibawah 0,05 dan dapat dikatakan peningkatan yang signifikan.

4. Kesimpulan

Dari penelitian yang telah dilakukan, dapat disimpulkan bahwa penelitian ini mengukuhkan hasil penelitian sebelumnya bahwa algoritma *Neural Network* dan Optimasi GA dapat memberikan hasil yang terbaik untuk memprediksi kasus penyakit ginjal kronik pada pasien berdasarkan atribut-atribut yang dimiliki pasien. Dari penelitian ini, tingkat akurasi tertinggi dari algoritma *Neural Network* dan optimasi GA yang diperoleh adalah 98,75% dengan nilai AUC sebesar 0,999. Hasil dari sebelum dan sesudah optimasi juga dilakukan analisa *t-test* untuk memastikan bahwa terjadi peningkatan yang signifikan dengan menambahkan optimasi berbasis GA kepada algoritma NN. Hasil analisa *t-test* dilihat dari *P-Value* yang dihasilkan, baik *one-tail* maupun *two-tail* keduanya bernilai dibawah 0,05 yang berarti hasil peningkatan persentase akurasi dapat dikatakan signifikan. Hasil-hasil tersebut, dapat menjadi kunci untuk pemanfaatan dan implementasi algoritma ini dalam bentuk sebuah sistem atau aplikasi yang dapat digunakan oleh tenaga medis dan lembaga kesehatan agar dapat dengan lebih cepat dan mudah memprediksi tingkat resiko penyakit ginjal kronis pada pasien sehingga meningkatkan peluang kesembuhan bagi para pasien tersebut.

Referensi

Ahmed, S., Ghosh, K. K., Singh, P. K., Geem, Z. W., & Sarkar, R. (2020). Hybrid of harmony search algorithm and ring

theory-based evolutionary algorithm for feature selection. *IEEE Access*, 8, 102629–102645.

- Almansour, N. A., Syed, H. F., Khayat, N. R., Altheeb, R. K., Juri, R. E., Alhiyafi, J., Alrashed, S., & Olatunji, S. O. (2019). Neural network and support vector machine for the prediction of chronic kidney disease: A comparative study. *Computers in Biology and Medicine*, 109, 101–111.
- Bai, Q., Su, C., Tang, W., & Li, Y. (2022). Machine learning to predict end stage kidney disease in chronic kidney disease. *Scientific Reports*, 12(1), 8377.
- Chittora, P., Chaurasia, S., Chakrabarti, P., Kumawat, G., Chakrabarti, T., Leonowicz, Z., Jasiński, M., Jasiński, L., Gono, R., & Jasińska, E. (2021). Prediction of chronic kidney disease-a machine learning perspective. *IEEE Access*, 9, 17312–17334.
- Dongare, A. D., Kharde, R. R., & Kachare, A. D. (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1), 189–194.
- Hore, S., Chatterjee, S., Shaw, R. K., Dey, N., & Virmani, J. (2018). Detection of chronic kidney disease: A NN-GA-based approach. *Nature Inspired Computing: Proceedings of CSI 2015*, 109–115.
- Japkowicz, N. (2006). Why question machine learning evaluation methods. *AAAI Workshop on Evaluation Methods for Machine Learning*, 6(11).
- Konak, A., Coit, D. W., & Smith, A. E. (2006). Multi-objective optimization using genetic algorithms: A tutorial. *Reliability Engineering & System Safety*, 91(9), 992–1007.
- Ling, C. X., Huang, J., & Zhang, H. (2003). AUC: a better measure than accuracy in comparing learning algorithms. *Advances in Artificial Intelligence: 16th Conference of the Canadian Society for Computational Studies of Intelligence, AI 2003, Halifax, Canada, June 11–13, 2003, Proceedings 16*, 329–341.
- Mishra, P., Singh, U., Pandey, C. M., Mishra, P., & Pandey, G. (2019). Application of student's t-test, analysis of variance, and covariance. *Annals of Cardiac Anaesthesia*, 22(4), 407–411.
- Nishat, M. M., Faisal, F., Dip, R. R., Nasrullah, S. M., Ahsan, R., Shikder, F.,

- Asif, M. A.-A.-R., & Hoque, M. A. (2021). A comprehensive analysis on detecting chronic kidney disease by employing machine learning algorithms. *EAI Endorsed Transactions on Pervasive Health and Technology*, 7(29), e1–e1.
- Polap, D. (2020). An adaptive genetic algorithm as a supporting mechanism for microscopy image analysis in a cascade of convolution neural networks. *Applied Soft Computing*, 97, 106824.
- Qezelbash-Chamak, J., Badamchizadeh, S., Eshghi, K., & Asadi, Y. (2022). A survey of machine learning in kidney disease diagnosis. *Machine Learning with Applications*, 10, 100418.
- Qin, J., Chen, L., Liu, Y., Liu, C., Feng, C., & Chen, B. (2019). A machine learning methodology for diagnosing chronic kidney disease. *IEEE Access*, 8, 20991–21002.
- Renear, A. H., Sacchi, S., & Wickett, K. M. (2010). Definitions of dataset in the scientific and technical literature. *Proceedings of the American Society for Information Science and Technology*, 47(1), 1–4.
- Seraj, A., Mohammadi-Khanaposhtani, M., Daneshfar, R., Naseri, M., Esmaili, M., Baghban, A., Habibzadeh, S., & Eslamian, S. (2023). Cross-validation. In *Handbook of Hydroinformatics* (pp. 89–105). Elsevier.
- Sil, A., Betkerur, J., & Das, N. K. (2019). P-value demystified. *Indian Dermatology Online Journal*, 10(6), 745–750.
- Singh, V., Asari, V. K., & Rajasekaran, R. (2022). A deep neural network for early detection and prediction of chronic kidney disease. *Diagnostics*, 12(1), 116.