

ANALISIS AKURASI ALGORITMA K-NEAREST NEIGHBOR BERBASIS PARTICLE SWARM OPTIMIZATION PADA STUDI KASUS DIAGNOSA PENYAKIT JANTUNG

Feri Tri Setiawan

Program Studi Magister Matematika, FMIPA, Universitas Lampung, Indonesia
97feri@gmail.com*

Khoirin Nisa

Jurusan Matematika, FMIPA, Universitas Lampung, Indonesia

Mustofa Usman

Jurusan Matematika, FMIPA, Universitas Lampung, Indonesia

Abstrak

Penyakit jantung merupakan salah satu penyebab utama kematian di dunia, sehingga deteksi dini menjadi aspek krusial dalam pengambilan keputusan medis. Penelitian ini bertujuan untuk meningkatkan akurasi klasifikasi diagnosa penyakit jantung dengan menggabungkan algoritma *K-Nearest Neighbor* (K-NN), *Particle Swarm Optimization* (PSO). K-NN dipilih karena kesederhanaannya dalam klasifikasi berbasis jarak, sementara PSO digunakan untuk mengoptimalkan parameter K secara otomatis guna meningkatkan performa prediksi. Data yang digunakan bersumber dari dataset terbuka berisi 300 data pasien, yang diolah melalui tahapan *preprocessing*, *splitting*, dan evaluasi multikolinearitas. Eksperimen dilakukan dengan empat skenario pembagian data (60:40, 70:30, 80:20, dan 90:10) dan perbandingan antara metode K-NN dan KNN-PSO. Hasil pengujian menunjukkan bahwa integrasi K-NN dengan PSO menghasilkan peningkatan akurasi signifikan dibandingkan K-NN murni. Akurasi terbaik tercapai pada skenario KNN-PSO dengan 20 partikel dan rasio data training-testing 90:10 dengan nilai $K = 4$, menghasilkan akurasi sebesar 80%. Temuan ini menunjukkan bahwa penggunaan PSO efektif dalam optimasi parameter pada algoritma K-NN untuk klasifikasi penyakit jantung, serta memberikan potensi untuk pengembangan sistem pendukung keputusan medis yang lebih akurat.

Kata Kunci: *K-Nearest Neighbor*, *Particle Swarm Optimization*, Diagnosa Penyakit Jantung, Klasifikasi, Optimasi Parameter.

Abstract

Heart disease is one of the leading causes of death worldwide, making early detection a crucial aspect in medical decision-making. This study aims to improve the accuracy of heart disease diagnosis classification by combining the *K-Nearest Neighbor* (K-NN) and *Particle Swarm Optimization* (PSO) algorithms. K-NN was chosen due to its simplicity in distance-based classification, while PSO is used to automatically optimize the K parameter to improve prediction performance. The data used is sourced from an open dataset containing 300 patient data, which is processed through *preprocessing*, *splitting*, and *multicollinearity evaluation* stages. Experiments were conducted with four data sharing scenarios (60:40, 70:30, 80:20, and 90:10) and a comparison between the K-NN and KNN-PSO methods. The test results show that the integration of K-NN with PSO results in a significant increase in accuracy compared to pure K-NN. The best accuracy was achieved in the KNN-PSO scenario with 20 particles and a training-testing data ratio of 90:10 with a K value of 4, resulting in an accuracy of 80%. These findings demonstrate the effectiveness of PSO in optimizing parameters in the K-NN algorithm for heart disease classification and offer potential for developing more accurate medical decision support systems.

Keywords: *K-Nearest Neighbor*, *Particle Swarm Optimization*, Heart Disease Diagnosis, Classification, Parameter Optimization.

PENDAHULUAN

Penyakit jantung merupakan penyebab utama kematian di dunia, sebagaimana dilaporkan oleh *World Health Organization* (WHO) bahwa pada tahun

2019 penyakit jantung iskemik menyumbang 16% dari seluruh kematian global. Deteksi dini penyakit ini menjadi sangat penting dalam meningkatkan kualitas hidup pasien dan mengurangi risiko kematian. Namun, proses diagnosis penyakit jantung

secara manual memiliki keterbatasan dalam hal kecepatan dan akurasi. Oleh karena itu, pendekatan berbasis teknologi, khususnya *machine learning*, menjadi solusi yang potensial dalam mendukung pengambilan keputusan medis.

Salah satu algoritma *Machine Learning* yang populer untuk klasifikasi adalah *K-Nearest Neighbor* (K-NN). K-NN dikenal karena kesederhanaannya dan efisiensinya dalam berbagai kasus klasifikasi, termasuk diagnosis medis [1]. Namun demikian, performa K-NN sangat bergantung pada pemilihan parameter K dan jenis metrik jarak yang digunakan. Pemilihan parameter yang tidak optimal dapat menyebabkan penurunan akurasi klasifikasi dan menimbulkan masalah seperti *overfitting* atau *underfitting*.

Untuk mengatasi keterbatasan tersebut, digunakan pendekatan berbasis optimasi yaitu *Particle Swarm Optimization* (PSO) [2]. PSO merupakan algoritma optimasi yang terinspirasi dari perilaku sosial kawanan burung atau ikan dalam mencari makanan. Dalam konteks klasifikasi, PSO digunakan untuk mencari nilai optimal dari parameter K pada algoritma K-NN, sehingga diharapkan dapat meningkatkan akurasi dalam proses diagnosis penyakit jantung. Kombinasi K-NN dengan PSO membentuk metode *hybrid* yang mampu mengatasi kelemahan masing-masing algoritma [3].


Berbagai penelitian sebelumnya menunjukkan bahwa pendekatan *hybrid* ini mampu meningkatkan performa prediksi secara signifikan. Misalnya, penelitian oleh Gao et al. [3] yang menggunakan metode ekstraksi ciri PCA dan *Bagging Ensemble Learning* dengan K-NN berhasil mencapai akurasi sebesar 98,1%. Sementara Bharti et al. [4] mencatat akurasi 94,2% menggunakan pendekatan *deep learning*. Oleh karena itu, penggabungan K-NN dengan PSO dalam studi ini bertujuan untuk mengeksplorasi potensi peningkatan akurasi dalam diagnosis penyakit jantung.

KAJIAN TEORI

Machine Learning adalah bidang keilmuan yang mempelajari tentang algoritma dan model statistik yang digunakan oleh sistem komputer untuk melakukan tugas tertentu tanpa instruksi eksplisit [5]. *Machine Learning* dapat dibedakan menjadi tiga

tipe yaitu *Supervised Learning*, *Unsupervised Learning* dan *Reinforcement Learning*.

Sebuah metode untuk melakukan klasifikasi terhadap obyek berdasarkan data pembelajaran yang jaraknya paling dekat dengan obyek tersebut. Prinsip kerja dari K-NN adalah mencari jarak terdekat antara data yang akan dievaluasi dengan *k* tetangga (*neighbor*) terdekatnya dalam data petrainan [6] (lihat ilustrasi pada Gambar 1).



Gambar 1. Kinerja Algoritma K-NN [7]

Euclidean Distance adalah perhitungan jarak dari dua buah titik dalam *euclidean space* untuk mempelajari hubungan antara sudut dan jarak. *Euclidean* ini berkaitan dengan teorema *pythagoras*. Perhitungan *Euclidean Distance* pada dua dimensi digunakan untuk dapat mengukur jarak pada koordinat *latitude* dan *longitude*. Untuk mengukur tingkat kemiripan data dengan rumus *Euclidean Distance* digunakan rumus berikut:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

dimana,

d = jarak antara x dan y

x = data training

y = data testing

i = indeks fitur ke i

n = jumlah fitur,

x_i = data training ke i

y_i = data testing ke i

Ecludian Distance sering digunakan untuk menghitung jarak. *Euclidian Distance* berfungsi

mengtesting ukuran yang bisa digunakan sebagai interpretasi kedekatan jarak antara dua objek [8].

Dalam klasifikasi, untuk memprediksi label kelas contoh baru, K-NN pertama menemukan k tetangga terdekatnya dari set petrainingan sesuai dengan jarak metrik dan kemudian memberikan label yang dominan antara tetangga k ke *instance* baru. Jika $k = 1$, label dari contoh baru ditentukan oleh tetangga terdekatnya. Karena yang implementasi kesederhanaan dan efektivitas klasifikasi, K-NN adalah biasa digunakan sebagai *classifier* standar untuk mengevaluasi dan membandingkan kinerja algoritma seleksi fitur yang berbeda dan terintegrasi ke dalam kerangka seleksi fitur untuk mengevaluasi kualitas subset fitur calon.

Algoritma PSO diperkenalkan oleh Eberhart dan Kennedy pada tahun 1995 [9]. PSO merupakan metode pencarian populasi yang terinspirasi dari pergerakan burung dan ikan dalam mencari makan. PSO banyak digunakan untuk memecahkan masalah optimasi dan masalah seleksi fitur [10]. Algoritma PSO adalah algoritma kecerdasan populasi *based swarm* yang pada awalnya diusulkan oleh Kennedy dan Eberhart dan mensimulasikan perilaku sosial organisme dengan menggunakan gerakan fisik dari individu dalam swarm.

Algoritma PSO menggunakan konsep *pbest* dan *gbest* yang mirip dengan operasi *crossover* pada *Genetic Algorithm* (GA) [11]. Setiap partikel diasumsikan mempunyai posisi dan kecepatan [12]. Algoritma PSO memperbaharui posisi dan kecepatan partikel pada setiap iterasi sehingga partikel tersebut dapat menghasilkan solusi baru yang lebih baik [13].

Secara matematis perbaikan ini menghasilkan persamaan berikut [14]:

$$V_{i,j}^{t+1} = w \cdot V_{i,j}^t + c_1 r_1 (Pbest_{i,j}^t - x_{i,j}^t) + c_2 r_2 (Gbest_{g,j}^t - x_{i,j}^t)$$

Dimana:

- $V_{i,j}^{t+1}$: Kecepatan untuk posisi yang dicapai
- w : Faktor inersia yang mengontrol pengaruh kecepatan sebelumnya.
- $V_{i,j}^t$: Kecepatan untuk posisi sekarang (awal)
- $c_1 r_1$: *Learning rate*
- $Pbest_{i,j}^t$: Posisi terbaik dari partikel i
- $x_{i,j}^t$: Posisi partikel i pada iterasi t
- $c_2 r_2$: Bilangan acak antara 0 dan 1
- $Gbest_{g,j}^t$: Posisi terbaik global populasi partikel

Confusion Matrix adalah pengukuran performa untuk masalah klasifikasi *machine learning* dimana keluaran dapat berupa dua kelas atau lebih. *Confusion Matrix* adalah tabel dengan 4 kombinasi berbeda dari nilai prediksi dan nilai aktual [15].

Berikut adalah struktur *confusion matrix*:

Predicted Actual	Positive (1)	Negative (0)
Positive (1)	True Positive (TP)	False Negative (FN)
Negative (0)	False Positive (FP)	True Negative (TN)

Tabel 1. *Confusion Matrix*

Penjelasan tabel *Confusion Matrix* di atas adalah sebagai berikut [16]:

1. *True Positive* (TP) : Jumlah prediksi yang benar, dimana nilai kelas aktual positif dan diprediksi sebagai positif.
2. *False Negative* (FN) : Jumlah prediksi yang salah, dimana nilai kelas aktual positif namun diprediksi sebagai negatif.
3. *False Positive* (FP) : Jumlah prediksi yang salah, dimana nilai kelas aktual negatif namun diprediksi sebagai positif.
4. *True Negative* (TN) : Jumlah prediksi yang benar, dimana nilai kelas aktual negatif dan diprediksi sebagai negatif.

Berikut adalah *performance measure* yang dapat diukur oleh *Confusion Matrix*[17]:

- a. *Accuracy*

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

- b. *Precision*

$$Precision = \frac{TP}{TP + FP}$$

- c. *Recall*

$$Recall = \frac{TP}{TP + FN}$$

- d. *Specificity*

$$Specificity = \frac{TN}{TN + FP}$$

- e. *F1-Score*

$$F1 - Score = 2 \times \frac{Recall \times Precision}{(Recall + Precision)}$$

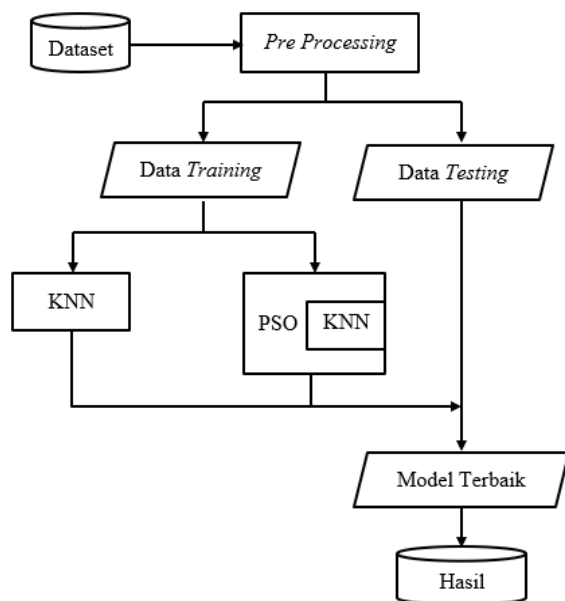
METODE

Penelitian ini menggunakan Algoritma *K-Nearest Neighbor* berbasis *Particle Swarm Optimization* pada diagnosa penyakit jantung dengan bantuan pemrograman Rstudio versi 4.4.1.

Data yang digunakan dalam penelitian ini adalah data sekunder yang bisa diakses melalui situs web www.kaggle.com. Data yang digunakan adalah data 300 pasien yang melakukan pemeriksaan penyakit jantung. Data penelitian ini memiliki 6 variabel sebagai atribut yaitu: usia (X_1), tekanan darah (X_2), kolesterol (X_3), detak jantung maksimal tercapai (X_4), depresi yang diakibatkan olahraga dibandingkan istirahat (X_5), dan 1 atribut kategori yang berisi ada penyakit jantung atau tidak ada penyakit jantung (Y). Untuk pembagian data dibagi menjadi empat skema seperti pada Tabel 1 dan diagram alir penelitian disajikan pada Gambar 2.

Tabel 1. Skenario Data Splitting

Skema	Data Training	Data Testing
60% - 40%	180	120
70% - 30%	210	90
80% - 20%	240	60
90% - 10%	270	30



Gambar 2. Diagram Alir Penelitian

HASIL DAN PEMBAHASAN


Dari 4 skenario *data splitting* akan ditentukan skema terbaik yang memiliki nilai akurasi yang paling tinggi. Dengan mencoba beberapa nilai K yaitu $k = 1, 2, \dots, 17$, diperoleh hasil nilai akurasi tertinggi dari setiap skema seperti disajikan pada Tabel 2.

Tabel 2. Hasil Akurasi Analisis K-NN

K	Skema 1	Skema 1	Skema 1	Skema 1
1	0,6250	0,6111	0,6000	0,7333
2	0,6083	0,5889	0,5333	0,7000
3	0,6167	0,5889	0,5500	0,7333
4	0,6500	0,6444	0,6000	0,7667
5	0,5667	0,6444	0,6667	0,7667
6	0,5500	0,5889	0,6333	0,8000
7	0,5750	0,5889	0,6333	0,7333
8	0,6333	0,6222	0,6333	0,7333
9	0,5917	0,6222	0,6500	0,7000
10	0,6250	0,6555	0,6833	0,7333
11	0,6250	0,6667	0,7000	0,7000
12	0,6417	0,6778	0,7333	0,7000
13	0,6500	0,6778	0,7000	0,6667
14	0,6500	0,6889	0,7333	0,7333
15	0,6250	0,6444	0,7167	0,7000
16	0,6500	0,6667	0,7667	0,6667
17	0,6083	0,6444	0,7333	0,7000

Berdasarkan hasil evaluasi akurasi model K-NN pada empat skema pembagian data (60:40, 70:30, 80:20 dan 90:10), dapat disimpulkan bahwa performa model sangat dipengaruhi oleh proporsi partisi data dan nilai parameter k . Dari Tabel 2, teramati bahwa skema 90%:10% menghasilkan akurasi tertinggi dibandingkan skenario lainnya, dengan nilai akurasi optimal sebesar 0.8 (80%) pada $k = 6$. Hal ini menunjukkan bahwa pembagian data dengan rasio 90% data training dan 10% data testing mampu menangkap pola klasifikasi lebih efektif, didukung oleh pemilihan k yang tepat. Nilai $k = 6$ terbukti optimal untuk skenario 90:10 karena mampu menyeimbangkan bias dan *variance*, menghindari *overfitting* (yang mungkin terjadi pada k kecil) atau *underfitting* (pada k besar). Sementara itu, skenario lain seperti 60:40 dan 70:30 cenderung memiliki akurasi lebih rendah (maksimal 0.688 pada $k = 14$), mengindikasikan bahwa proporsi data training yang lebih kecil mungkin kurang memadai untuk melatih model yang *robust*.

Berdasarkan hasil evaluasi terhadap empat skenario nilai k pada algoritma K-NN dalam mendiagnosis penyakit jantung, diperoleh variasi performa yang signifikan terhadap masing-masing matrik evaluasi, yaitu Akurasi, *True Positive (TP)*, *False Positive (FP)*, *True Negative (TN)*, dan *False Negative (FN)*. Skenario 4, dengan nilai $k = 6$, menunjukkan performa terbaik dengan akurasi sebesar 80%, TP sebesar 83,33%, FP sebesar 37,5%, TN sebesar 62,5%, dan FN terendah yakni 16,67%. Nilai TP yang tinggi menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengidentifikasi pasien yang benar-benar menderita penyakit jantung. Di sisi lain, nilai FN yang rendah memperkuat keandalan model dalam meminimalkan kesalahan diagnosis terhadap pasien yang seharusnya mendapatkan perawatan medis segera.




Gambar 3. Perbandingan Kinerja K-NN

Sementara itu, skema lainnya menunjukkan performa yang relatif lebih rendah. Misalnya, Skenario 1 pada beberapa nilai k (4, 13, 14, 16) menghasilkan akurasi terendah yaitu 65%, disertai dengan TP sekitar 70% dan FN yang cukup tinggi, yaitu sekitar 30%. Hal ini menunjukkan bahwa model cenderung gagal mengenali sekitar sepertiga pasien yang seharusnya terdiagnosis sakit. Meski terdapat perbaikan bertahap pada Skenario 2 ($k = 14$) dan Skenario 3 ($k = 16$), peningkatan kinerja yang signifikan baru terlihat pada Skenario 4. Fakta ini menunjukkan bahwa pemilihan nilai k yang tepat sangat memengaruhi performa K-NN, khususnya dalam konteks medis yang sangat sensitif terhadap kesalahan klasifikasi.

Berikutnya dilakukan analisis menggunakan algoritma hybrid K-NN - PSO menggunakan 10 dan 20 partikel dengan beberapa model yaitu model K-NN, dan model K-NN - PSO. Dari hasil optimasi

menggunakan semua model didapatkan hasil akurasi seperti yang disajikan pada Gambar 4.

Dari Gambar 4 dapat dilihat bahwa algoritma optimasi K-NN - PSO memberikan nilai k optimum yang berbeda dengan K-NN, terbukti PSO memberikan nilai akurasi yang lebih tinggi dari pada akurasi K-NN tanpa PSO. Setelah dilakukan optimasi, nilai akurasi tertinggi terdapat pada skenario 4 (90:10) dengan nilai akurasi sebesar 0,833 dengan nilai optimasi K sebesar 4, baik pada 10 maupun 20 partikel.



Tabel 4. Hasil Akurasi K-NN - PSO

Untuk menentukan jumlah partikel mana yang terbaik pada 4 skenario, kita perlu melihat perkembangan nilai *Global Best Fitness* pada saat iterasi berlangsung. Hal tersebut dapat dilihat dalam rangkuman di Tabel 3 berikut.

Tabel 3. Rekapitulasi Hasil Akurasi

Iterasi	K-NN	K-NN - PSO 10 Partikel	K-NN - PSO 20 Partikel
10	0,800	0,767	0,833
20	0,800	0,800	0,833
30	0,800	0,833	0,833
40	0,800	0,833	0,833
50	0,800	0,833	0,833

Dari hasil diatas, dapat diketahui bahwa 20 partikel memberikan performa yang lebih baik dari pada K-NN - PSO dengan 10 partikel. Maka dari itu, pada penelitian ini, didapatkan akurasi terbaik sebesar 0,833 yang didapat dari K-NN - PSO 20 partikel, dengan 50 iterasi, dengan k optimum = 4.

PENUTUP

SIMPULAN

Penelitian ini bertujuan untuk menganalisis akurasi Algoritma *K-Nearest Neighbor* (K-NN) yang dioptimalkan dengan metode *Particle Swarm Optimization* (PSO) dalam studi kasus diagnosis penyakit jantung. Berdasarkan skenario pengujian dengan pembagian data sebesar 90% untuk data training dan 10% untuk data testing, diperoleh hasil akurasi tertinggi sebesar 0,833. Akurasi ini dicapai pada konfigurasi K-NN - PSO dengan 20 partikel, 50 iterasi, dan nilai *k* optimum sebesar 4. Hasil tersebut menunjukkan bahwa pendekatan PSO secara efektif dapat meningkatkan performa algoritma K-NN dalam mengklasifikasikan data medis, khususnya dalam mendeteksi penyakit jantung.

SARAN

Berdasarkan kesimpulan telah diuraikan, penelitian tentang analisis akurasi algoritma K-NN berbasis PSO pada studi kasus diagnosa penyakit jantung menghasilkan beberapa saran untuk penelitian serupa di masa depan, yaitu:

1. Disarankan agar peneliti selanjutnya mempertimbangkan penggunaan metode optimasi lain seperti *Genetic Algorithm* (GA) atau *Differential Evolution* (DE) sebagai pembanding untuk mengevaluasi performa optimasi yang lebih optimal.
2. Selanjutnya disarankan untuk menggunakan teknik validasi silang (*cross-validation*) seperti *k-fold* untuk memperoleh hasil evaluasi model yang lebih robust dan mengurangi risiko *overfitting* pada pembagian data tertentu.

DAFTAR PUSTAKA

- [1] Y. S. Kwak, M. Kim, and M. S. Kang, "Turkish Journal of Computer and Mathematics Education A Study on GBW-KNN Using Statistical Testing Research Article," vol. 12, no. 5, pp. 271-277, 2021.
- [2] Y. Marinakis, "An improved particle swarm optimization algorithm for the capacitated location routing problem and for the location routing problem with stochastic demands," *Appl. Soft Comput. J.*, vol. 37, pp. 680-701, 2015, doi: 10.1016/j.asoc.2015.09.005.
- [3] X. Y. Gao, A. Amin Ali, H. Shaban Hassan, and E. M. Anwar, "Improving the Accuracy for Analyzing Heart Diseases Prediction Based on the Ensemble Method," *Complexity*, vol. 2021, 2021, doi: 10.1155/2021/6663455.
- [4] R. Bharti, A. Khamparia, M. Shabaz, G. Dhiman, S. Pande, and P. Singh, "Prediction of Heart Disease Using a Combination of Machine Learning and Deep Learning," *Comput. Intell. Neurosci.*, vol. 2021, 2021, doi: 10.1155/2021/8387680.
- [5] R. K. Dinata and N. Hasdyna, "Machine Learning.pdf," p. 23, 2020.
- [6] J. Sreemathy, "an Efficient Text Classification Using Knn and Naive Bayesian," vol. 4, no. 03, pp. 392-396, 2012.
- [7] S. Kumar (2020). Basics of K-Nearest Neighbor Algorithm. AITUDE. Diakses pada 12 Mei 2025. Dari <https://www.aitude.com/basics-of-k-nearest-neighbor-algorithm/>
- [8] Jasmir, D. Z. Abidin, S. Nurmaini, and R. F. Malik, "Penerapan Metode K-Nearest Neighbor dalam Memprediksi Masa Studi Mahasiswa (Studi Kasus : Mahasiswa STIKOM Dinamika Bangsa)," *Pros. Annu. Res. Semin.*, vol. 3, no. 1, pp. 133-138, 2017.
- [9] L. Zhang, Q. Fu, J. Chen, H. Bai, and X. Zhou, "A modified particle swarm optimization algorithm - CPSODE," *Proc. 29th Chinese Control Decis. Conf. CCDC 2017*, vol. 11, no. 10, pp. 6659-6663, 2017, doi: 10.1109/CCDC.2017.7978374.
- [10] F. Pramono, Didi Rosiyadi, and Windu Gata, "Integrasi N-gram, Information Gain, Particle Swarm Optimization di Naïve Bayes untuk Optimasi Sentimen Google Classroom," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 3, no. 3, pp. 383-388, 2019, doi: 10.29207/resti.v3i3.1119.
- [11] A. Setiawan, L. W. Santoso, and R. Adipranata, "Penerapan Algoritma Particle Swarm Optimization (PSO) untuk Optimisasi Pembangunan Negara dalam Turn Based Strategy Game," *J. Infra*, vol. 7, no. 1, pp. 249-255, 2019.
- [12] M. R. Lubis, "Metode Hybrid Particle Swarm Optimization - Neural Network Backpropagation Untuk Prediksi Hasil Pertandingan Sepak Bola," *J-SAKTI (Jurnal Sains Komput. dan Inform.)*, vol. 1, no. 1, p. 71, 2017, doi: 10.30645/j-sakti.v1i1.30.
- [13] D. Ariani, A. Fahriza, and I. Prasetyaningrum, "Optimasi Penjadwalan Mata Kuliah di Jurusan Teknik Informatika PENS dengan Menggunakan Algoritma Particle Swarm

- Optimization (PSO)," *EEPIS Repos.*, no. January, pp. 1-11, 2011.
- [14] K. W. Mahardika, Y. A. Sari, and A. Arwan, "Optimasi K-Nearest Neighbour Menggunakan Particle Swarm Optimization pada Sistem Pakar untuk Monitoring Pengendalian Hama pada Tanaman Jeruk," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 9, pp. 3333-3344, 2018.
- [15] J. Xu, Y. Zhang, and D. Miao, "Three-way confusion matrix for classification: A measure driven view," *Inf. Sci. (Ny).*, vol. 507, pp. 772-794, 2020, doi: 10.1016/j.ins.2019.06.064.
- [16] V. Wahyuningrum, "Penerapan Radial Basis Function Neural Network dalam Pengklasifikasian Daerah Tertinggal di Indonesia," *J. Apl. Stat. Komputasi Stat.*, vol. 12, no. 1, p. 37, 2020, doi: 10.34123/jurnalasks.v12i1.250.
- [17] B. Panjaitan and K. M. Lhaksana, "Analisis Sentimen Publik Terhadap Calon Presiden 2019 Melalui Twitter Menggunakan Metode Naive Bayes Classifier (Studi kasus: Pilpres 2019)," *Proceeding Eng.*, vol. 6, no. 2, p. 9745, 2019, [Online]. Available: www.cnnindonesia.com,