

# Optimizing Neural Networks Using Particle Swarm Optimization (PSO) Algorithm for Hypertension Disease Prediction

Sudriyanto<sup>1</sup>

<sup>1</sup> Universitas Nurul Jadid, Probolinggo, Jawa Timur, Indonesia

## Article Info

### Article history:

Diterima 5 September 2023

Revisi 10 September 2023

Diterbitkan 27 Oktober, 2023

### Keywords:

Hypertension,  
Neural Networks,  
Particle Swarm Optimization,  
Prediksi

## ABSTRAK

Penyakit hipertensi atau tekanan darah tinggi merupakan masalah kesehatan yang signifikan secara global. Prediksi yang akurat tentang risiko hipertensi dapat membantu dalam pencegahan, diagnosa, dan pengobatan dini. Dalam penelitian ini, kami mengusulkan penggunaan algoritma *Particle Swarm Optimization* (PSO) untuk mengoptimalkan jaringan saraf dalam prediksi penyakit hipertensi. Metode ini menggabungkan keunggulan jaringan saraf dalam pemodelan yang kompleks dengan kemampuan PSO dalam mencari solusi optimal. Proses optimisasi dilakukan dengan mengatur bobot dan bias dalam jaringan saraf menggunakan PSO. Kami menggunakan dataset yang telah dipersiapkan dengan fitur-fitur yang relevan untuk prediksi hipertensi. Performa jaringan saraf sebelum dan sesudah optimisasi dievaluasi menggunakan metrik evaluasi seperti *Root Mean Squared Error* (RMSE) dan *Squared Error*. *Neural Network* plus *Particle Swarm Optimization* (NN + PSO) menghasilkan nilai *Root Mean Square Error* (RMSE) yang lebih rendah (0.170) dibandingkan dengan metode *Neural Network* (NN) tanpa *Particle Swarm Optimization* (0.197). Selain itu, metode NN berbasis PSO juga menghasilkan *squared error* yang lebih rendah (0.029) dibandingkan dengan NN (0.039). Hasil eksperimen menunjukkan bahwa penggunaan algoritma PSO meningkatkan performa neural network dalam prediksi hipertensi. Terdapat penurunan yang signifikan dalam nilai RMSE dan *squared error* setelah mengoptimalkan neural network menggunakan PSO. Hal ini menunjukkan bahwa prediksi yang dihasilkan lebih dekat dengan nilai sebenarnya, dan tingkat akurasi prediksi meningkat.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



## Corresponding Author:

Sudriyanto,

Universitas Nurul Jadid, Ds. Krampilan Besuk, Probolinggo 67283, Indonesia

Email: sudriyanto@unuja.ac.id

## 1. PENDAHULUAN

Penyakit hipertensi, atau tekanan darah tinggi, merupakan salah satu masalah kesehatan yang serius dan umum terjadi di seluruh dunia [1]. Kondisi ini dapat meningkatkan risiko terjadinya penyakit jantung, stroke, dan penyakit vaskular lainnya. Menurut *World Health Organization* (WHO), hipertensi, yang juga dikenal sebagai tekanan darah tinggi, adalah kondisi medis yang ditandai oleh tekanan darah yang terus-menerus tinggi di dalam arteri [2][3]. WHO menganggap hipertensi sebagai masalah kesehatan global yang serius karena dapat meningkatkan risiko penyakit jantung, stroke, gagal ginjal, dan masalah kesehatan lainnya, sekitar 1,13 miliar orang di seluruh dunia menderita hipertensi pada tahun 2015, dan jumlah ini diperkirakan akan terus meningkat [4][5].

Prediksi penyakit hipertensi menjadi penting dalam upaya pencegahan dan penanganan dini [6][7]. Penggunaan teknologi dan analisis data, seperti penggunaan *Neural Networks*, dapat membantu dalam memprediksi risiko hipertensi pada individu berdasarkan faktor-faktor yang relevan seperti usia, jenis kelamin, riwayat keluarga, indeks massa tubuh, kadar kolesterol, dan lain-lain [8]. Meskipun *Neural Networks* telah digunakan secara luas dalam pemodelan dan prediksi, optimisasi model *Neural Networks* masih merupakan tantangan. Pemilihan

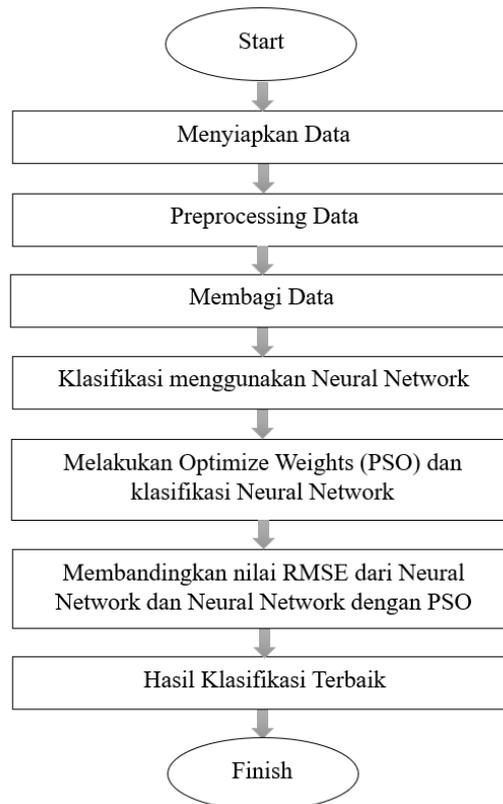
bobot dan bias yang optimal untuk *Neural Networks* adalah proses yang rumit dan memerlukan penyesuaian yang tepat untuk mencapai kinerja yang optimal [9]. Metode optimisasi tradisional seperti algoritma genetika dan penurunan *gradien stokastik (stochastic gradient descent)* mungkin menghadapi kendala dalam menemukan solusi terbaik dalam ruang pencarian yang besar dan kompleks [10], [11].

Dalam konteks ini, algoritma *Particle Swarm Optimization (PSO)* menawarkan pendekatan yang menarik untuk mengoptimalkan *Neural Networks* dalam prediksi penyakit hipertensi [12]. PSO adalah algoritma *metaheuristik* yang dapat mengatasi beberapa kendala dalam pencarian ruang parameter yang kompleks [13] [14]. Dengan menggabungkan kecerdasan kolektif dan adaptasi, PSO dapat membantu dalam menemukan bobot dan bias yang optimal untuk *Neural Networks* yang dapat memberikan prediksi yang akurat dalam hal hipertensi [15].

Dengan menggunakan algoritma *Particle Swarm Optimization (PSO)* untuk optimisasi *Neural Networks* dalam prediksi penyakit hipertensi, diharapkan dapat meningkatkan kinerja model prediktif dan membantu dalam identifikasi dini individu yang berisiko tinggi terkena hipertensi [16]. Hal ini dapat membantu dalam pencegahan, pengelolaan, dan penanganan penyakit hipertensi secara lebih efektif, serta meningkatkan kualitas hidup pasien dan mengurangi dampak negatif dari penyakit tersebut.

## 2. METODE

Data yang digunakan dalam penelitian ini merupakan data penyakit hipertensi yang diperoleh dari [https://www.kaggle.com/datasets/prosperchuks/health-dataset?select=hypertension\\_data.csv](https://www.kaggle.com/datasets/prosperchuks/health-dataset?select=hypertension_data.csv) [17]. Penelitian ini melibatkan 26084 pasien yang menderita hipertensi, termasuk pasien dengan tekanan darah normal dan pasien dengan hipertensi. Dalam penelitian ini, terdapat dua jenis variabel yang digunakan, yaitu variabel dependen yang merupakan status pasien (0 untuk tidak berisiko dan 1 untuk berisiko), dan variabel independen yang terdiri dari enam variabel, seperti *age* ( $x_1$ ), *sex* ( $x_2$ ), *cp* ( $x_3$ ), *trestbps* ( $x_4$ ), *chol* ( $x_5$ ), *fbs* ( $x_6$ ), *restecg* ( $x_7$ ), *thalach* ( $x_8$ ), *exang* ( $x_9$ ), *oldpeak* ( $x_{10}$ ), *slope* ( $x_{11}$ ), *ca* ( $x_{12}$ ), *thal* ( $x_{13}$ ). Penelitian ini dilakukan melalui langkah-langkah analisis pada gambar 1:



Gambar 1. Kerangka Penelitian

1. Menyiapkan Data: Tahap pertama adalah menyiapkan data pasien hipertensi yang terbagi menjadi variabel target dan variabel prediktor.

2. Preprocessing Data: Data kemudian akan diproses, termasuk pembersihan data dari missing values, normalisasi atau standardisasi, konversi data kategorikal menjadi numerik, dan reduksi dimensi jika diperlukan.
3. Membagi Data: Data akan dibagi menjadi dua bagian, yaitu data training dan data testing.
4. Klasifikasi menggunakan *Neural Network*: Model *Neural Network* akan dibangun dan dilatih menggunakan data training.
5. Melakukan *Optimize Weights* (PSO) dan klasifikasi *Neural Network*: Proses *Optimize Weights* (PSO) akan digunakan untuk mencari parameter optimal dalam model *Neural Network*, dan model akan dilatih dengan bobot dan bias yang telah dioptimasi.
6. Membandingkan nilai RMSE dan SE dari *Neural Network* dan *Neural Network* dengan PSO: Nilai RMSE dan SE dari kedua metode akan dihitung dan dibandingkan untuk menentukan performa terbaik.
7. Hasil Klasifikasi Terbaik: Hasil klasifikasi terbaik akan didapatkan berdasarkan perbandingan nilai RMSE dan SE, dan model dengan performa terbaik dapat digunakan untuk prediksi data pasien hipertensi.

### 3. HASIL DAN PEMBAHASAN

Penelitian ini melibatkan 7 tahapan utama, yakni Menyiapkan data, Melakukan *preprocessing*, Membagi data menjadi data *training* dan *testing*, Melakukan klasifikasi menggunakan metode *Neural Network*, Melakukan proses *Optimize Weights* (PSO) dan melakukan klasifikasi *Neural Network* dengan PSO, Membandingkan nilai *Root Mean Square Error* (RMSE) dan *Squared Error* (SE) dari *Neural Network* dan *Neural Network* dengan PSO dan yang terakhir memperoleh hasil klasifikasi terbaik dari kedua metode dari nilai *Root Mean Square Error* (RMSE) dan *Squared Error* (SE). Penelitian ini menghasilkan prediksi yang dapat digunakan sebagai pedoman dalam pengambilan keputusan bagi pasien yang beresiko hipertensi.

#### 3.1 Menyiapkan data untuk klasifikasi

Pada tahap awal menyiapkan data untuk klasifikasi menggunakan data pasien hipertensi yang terbagi menjadi variabel target dan variabel prediktor. Penelitian ini melibatkan 26084 pasien yang menderita penyakit hipertensi, termasuk pasien dengan tekanan darah normal dan pasien dengan hipertensi. Pada penelitian ini variabel yang digunakan sebanyak 14 variabel terbagi menjadi dua antara variabel 13 variabel independent dan 1 variabel dependent. Untuk lebih jelasnya dapat ditampilkan pada table 1.

Tabel 1. Variabel Dataset Hipertensi

No	Variabel	Keterangan	Kategori variabel
1	<i>age</i>	Merupakan variabel yang mengacu pada usia pasien. Variabel ini dapat digunakan untuk mempelajari korelasi antara usia dengan risiko hipertensi.	<i>Independent</i>
2	<i>sex</i>	Merupakan variabel yang menunjukkan jenis kelamin pasien. Biasanya diwakili dengan angka, misalnya 0 untuk perempuan dan 1 untuk laki-laki. Variabel ini dapat digunakan untuk menganalisis perbedaan risiko hipertensi antara jenis kelamin.	<i>Independent</i>
3	<i>cp</i>	Merupakan kependekan dari " <i>chest pain</i> " atau nyeri dada. Variabel ini mengindikasikan tingkat nyeri dada yang dirasakan oleh pasien. Variabel ini dapat memberikan informasi tentang gejala yang berkaitan dengan hipertensi.	<i>Independent</i>
4	<i>trestbps</i>	Merupakan tekanan darah istirahat pasien ( <i>resting blood pressure</i> ) yang diukur dalam mmHg (milimeter raksa). Variabel ini memberikan informasi mengenai tingkat tekanan darah pasien saat beristirahat.	<i>Independent</i>
5	<i>chol</i>	Merupakan kadar kolesterol total pasien yang diukur dalam mg/dL (miligram per desiliter). Variabel ini dapat mengindikasikan hubungan antara kadar kolesterol dan risiko hipertensi.	<i>Independent</i>
6	<i>fbs</i>	Merupakan kependekan dari " <i>fasting blood sugar</i> " atau kadar gula darah puasa. Variabel ini mengacu pada kadar gula darah pasien	<i>Independent</i>

		setelah berpuasa. Variabel ini dapat memberikan informasi tentang hubungan antara kadar gula darah dan hipertensi.	
7	<i>restecg</i>	Merupakan <i>elektrokardiogram</i> (EKG) istirahat pasien. Variabel ini menggambarkan hasil tes EKG dan dapat memberikan informasi tentang kondisi jantung pasien.	<i>Independent</i>
8	<i>thalach</i>	Merupakan detak jantung maksimum yang dicapai pasien saat melakukan tes olahraga atau aktivitas fisik. Variabel ini diukur dalam jumlah detak per menit.	<i>Independent</i>
9	<i>exang</i>	Merupakan kependekan dari " <i>exercise induced angina</i> " atau angina yang disebabkan oleh aktivitas fisik. Variabel ini mengindikasikan apakah pasien mengalami angina saat melakukan aktivitas fisik.	<i>Independent</i>
10	<i>oldpeak</i>	Merupakan penurunan segmen ST pada EKG yang dihasilkan selama tes olahraga atau aktivitas fisik. Variabel ini dapat memberikan informasi tentang gangguan aliran darah ke jantung.	<i>Independent</i>
11	<i>slope</i>	Merupakan kemiringan segmen ST pada EKG selama tes olahraga. Variabel ini menggambarkan pola perubahan segmen ST selama aktivitas fisik.	<i>Independent</i>
12	<i>ca</i>	Merupakan jumlah pembuluh darah utama ( <i>major vessels</i> ) yang diwarnai oleh zat pewarna pada fluoroskopi. Variabel ini memberikan informasi tentang jumlah pembuluh darah yang mungkin tersumbat atau mengalami gangguan.	<i>Independent</i>
13	<i>thal</i>	Merupakan jenis kelainan yang terdeteksi pada tes thalassemia. Variabel ini menggambarkan jenis kelainan darah yang dapat berpengaruh terhadap risiko hipertensi.	<i>Independent</i>
14	<i>target</i>	Merupakan variabel target yang menunjukkan apakah pasien memiliki risiko hipertensi atau tidak. Biasanya diwakili dengan angka, misalnya 0 untuk tidak berisiko dan 1 untuk berisiko.	<i>Dependent</i>

Variabel-variabel tersebut merupakan atribut-atribut yang dianggap relevan dan dapat memberikan wawasan tentang faktor-faktor yang mempengaruhi hipertensi serta membantu dalam pembangunan model prediksi atau analisis lebih lanjut terkait kondisi tersebut.

### 3.2 Preprocessing pada data pasien hipertensi

*Preprocessing* pada data pasien hipertensi adalah serangkaian langkah yang dilakukan untuk membersihkan, mengubah format, dan menyiapkan data pasien hipertensi sebelum dianalisis menggunakan algoritma machine learning atau metode lainnya. Tujuan dari *preprocessing* ini adalah untuk memastikan data siap digunakan dan memberikan hasil yang akurat dan siap untuk diproses. *Tool* yang digunakan pada penelitian ini adalah rapidminer operator yang digunakan *Replace Missing Values* pada variable jenis kelamin terdeteksi ada 10 *missing value* parameter yang digunakan adalah atribut filter all dan diganti nilai rata-rata. Proses selanjutnya setelah dilakukan *preprocessing* data dan dinyatakan bersih maka dilakukan proses pemodelan dengan algoritma *Neural Network* dan *Optimize Weights* (PSO) plus klasifikasi *Neural Network*

### 3.3 Klasifikasi menggunakan metode Neural Network

Klasifikasi menggunakan metode *Neural Network* adalah salah satu pendekatan populer dalam pembelajaran mesin. *Neural Network* adalah model matematika yang terinspirasi oleh struktur dan fungsi otak manusia. Metode ini menggunakan beberapa lapisan (*layer*) yang terdiri dari neuron buatan (unit pengolahan informasi) yang saling terhubung untuk mempelajari pola-pola kompleks dalam data. Parameter yang digunakan *Cross Validation* dengan number of folds 10 dan *sampling type linear sampling*, untuk parameter *neural network* yang digunakan adalah *training cycle* 200, *learning rate* 0.01, *momentum* 0.9 dan *error epsilon* 1.0E-4. Hasil *Root Mean Square Error* (RMSE) dan *Squared Error* (SE) yang diperoleh dapat ditampilkan pada tabel 2.

Tabel 2. Hasil RMSE dan SE *Neural Network*

<i>Metric</i>	<i>Value</i>	<i>Standard Deviation</i>
<i>Root Mean Squared Error</i>	0.197	0.022
<i>Micro Average RMSE</i>	0.198	0.000
<i>Squared Error</i>	0.039	0.008
<i>Micro Average SE</i>	0.039	0.123

Nilai RMSE sebesar 0.197 menunjukkan tingkat kesalahan rata-rata antara prediksi dan nilai sebenarnya. *Standar deviasi* sebesar 0.022 menunjukkan variasi RMSE dalam evaluasi yang berbeda. *Micro average RMSE* sebesar 0.198 mencerminkan rata-rata RMSE untuk keseluruhan dataset. Demikian pula, nilai *squared error* sebesar 0.039 menunjukkan sejauh mana prediksi model mendekati nilai sebenarnya. Standar deviasi sebesar 0.008 menunjukkan variasi *squared error*. *Micro average squared error* sebesar 0.039 mencerminkan rata-rata *squared error* untuk keseluruhan dataset.

Data ini memberikan gambaran tentang performa model *Neural Network* dalam memprediksi penyakit hipertensi. Nilai yang lebih rendah untuk RMSE dan *squared error* menunjukkan akurasi yang lebih baik dan kesesuaian yang lebih dekat dengan data aktual. Pada variabel *Mean Value* mengacu pada nilai rata-rata dari metrik yang diberikan, variabel *Standard Deviation* mengacu pada simpangan baku (deviasi standar) dari metrik yang diberikan dan Variabel *Micro Average* mengacu pada rata-rata mikro (*micro average*) dari metrik yang diberikan.

### 3.4 Klasifikasi menggunakan metode *Neural Network* dan *Optimize Weights (PSO)*

Klasifikasi menggunakan metode *Neural Network* dengan pengoptimalan bobot menggunakan *Particle Swarm Optimization (PSO)* adalah kombinasi yang menarik untuk memperoleh hasil yang lebih baik. Dalam metode *optimize weights* menggunakan *Particle Swarm Optimization (PSO)*, bobot dan bias dalam *Neural Network* diperbarui dengan memanfaatkan konsep pergerakan partikel. PSO merupakan algoritma optimisasi yang terinspirasi dari perilaku kawanan partikel dalam mencari makanan.

Setiap partikel dalam algoritma PSO mewakili satu set solusi, dalam konteks ini, bobot dan bias dalam jaringan. Partikel-partikel ini bergerak dalam ruang pencarian untuk menemukan kombinasi bobot dan bias yang menghasilkan performa yang lebih baik. Pada aplikasi rapidminer dengan parameter *Optimize Weights (PSO)* pengaturan yang digunakan adalah *population size 5, maximum number of generations 30, inertia weight 1.0, local best weight 1.0, global best weight 1.0, min weight 0.0 dan max weight 1.0*. hasil yang diperoleh. Hasil *Root Mean Square Error (RMSE)* dan *Squared Error (SE)* yang diperoleh dapat ditampilkan pada table 3.

Tabel 3. Hasil RMSE dan SE *Neural Network* plus *Optimize Weights (PSO)*

<i>Metric</i>	<i>Value</i>	<i>Standard Deviation</i>
<i>Root Mean Squared Error</i>	0.170	0.026
<i>Micro Average RMSE</i>	0.172	0.000
<i>Squared Error</i>	0.029	0.008
<i>Micro Average SE</i>	0.029	0.117

Nilai RMSE sebesar 0.170 menunjukkan tingkat kesalahan rata-rata antara prediksi dan nilai sebenarnya. *Standar deviasi* sebesar 0.026 menunjukkan variasi RMSE dalam evaluasi yang berbeda. *Micro average RMSE* sebesar 0.172 mencerminkan rata-rata RMSE untuk keseluruhan dataset. Demikian pula, nilai *squared error* sebesar 0.029 menunjukkan sejauh mana prediksi model mendekati nilai sebenarnya. Standar deviasi sebesar 0.008 menunjukkan variasi *squared error*. *Micro average squared error* sebesar 0.029 mencerminkan rata-rata *squared error* untuk keseluruhan dataset.

Data ini memberikan gambaran tentang performa model *Neural Network plus Particle Swarm Optimization* (PSO) dalam memprediksi penyakit hipertensi. Perhatikan bahwa menggunakan PSO dalam mengoptimalkan *Neural Network* telah menghasilkan penurunan RMSE dan *squared error*. Hal ini menunjukkan peningkatan dalam akurasi prediksi dan kemampuan model untuk mendekati nilai sebenarnya.

### 3.5 Membandingkan nilai *Root Mean Square Error* dan *Squared Error* pada *Neural Network* dan *Neural Network plus Optimize Weights* (PSO).

Untuk membandingkan nilai *Root Mean Square Error* (RMSE) terbaik antara *Neural Network* (NN) dan *Neural Network plus Optimize Weights* menggunakan *Particle Swarm Optimization* (NN + PSO), kita perlu melihat hasil pelatihan dan evaluasi kinerja keduanya. Dalam *Neural Network* (NN) standar, RMSE dihitung sebagai metrik evaluasi yang mengukur sejauh mana prediksi jaringan berbeda dari nilai target yang sebenarnya. Proses pembelajaran NN melibatkan *feedforward*, perhitungan kesalahan, dan *backpropagation* untuk memperbarui bobot dan bias dalam jaringan. Sementara itu, dalam *Neural Network plus Optimize Weights* menggunakan *Particle Swarm Optimization* (NN + PSO), metode PSO digunakan untuk memperbarui bobot dan bias dalam jaringan. Algoritma PSO membantu mencari kombinasi bobot dan bias yang memberikan performa yang lebih baik dalam klasifikasi. Dengan menggunakan PSO, diharapkan jaringan dapat mencapai hasil yang lebih optimal dibandingkan dengan NN standar.

Untuk membandingkan nilai RMSE terbaik dari kedua metode, kita harus melatih kedua jaringan dengan dataset yang sama dan melakukan evaluasi dengan menggunakan metrik RMSE pada data validasi atau data tes terpisah. Setelah itu, kita dapat membandingkan RMSE terbaik yang dicapai oleh masing-masing metode. Hasil RMSE antara metode *Neural Network* (NN) dan *Neural Network plus Optimize Weights* using *Particle Swarm Optimization* (NN + PSO) ditampilkan pada table 4.

Tabel 4. Perbandingan hasil klasifikasi *Neural Network plus Optimize Weights* (PSO)

Metode	RMSE	RMSE (micro average)	<i>Squared Error</i>	<i>Squared Error</i> (micro average)
<i>Neural Network</i>	0.197	0.198	0.039	0.039
<i>Neural Network + Particle Swarm Optimization</i> (PSO)	0.170	0.172	0.029	0.029

Dari tabel tersebut, terlihat bahwa *Neural Network plus Particle Swarm Optimization* (NN + PSO) menghasilkan nilai RMSE yang lebih rendah (0.170) dibandingkan dengan *Neural Network* (NN) tanpa PSO (0.197). Penurunan nilai RMSE ini menunjukkan bahwa dengan menggunakan PSO untuk mengoptimalkan bobot dan bias dalam *Neural Network*, prediksi model menjadi lebih akurat dalam memprediksi penyakit hipertensi.

## 4. KESIMPULAN

Berdasarkan hasil dan pembahasan pada penelitian ini, dapat disimpulkan bahwa metode *Neural Network plus Particle Swarm Optimization* (NN + PSO) menghasilkan nilai *Root Mean Square Error* (RMSE) dan *Squared Error* yang lebih rendah (0.170) dibandingkan dengan metode *Neural Network* (NN) tanpa *Particle Swarm Optimization* (0.197). Selain itu, metode NN + PSO juga menghasilkan *squared error* yang lebih rendah (0.029) dibandingkan dengan NN (0.039). Penurunan nilai RMSE dan *squared error* ini menunjukkan bahwa penggunaan algoritma *Particle Swarm Optimization* dalam mengoptimalkan *Neural Network* dapat meningkatkan akurasi prediksi dan mengurangi kesalahan prediksi dalam prediksi penyakit hipertensi.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang tulus kepada Universitas Nurul Jadid atas dukungan dan sponsor yang telah diberikan dalam penelitian ini. Kontribusi keuangan yang diberikan oleh Universitas Nurul Jadid sangat berharga dalam menjalankan penelitian ini dan memungkinkan kami untuk melakukan eksplorasi yang lebih mendalam dalam bidang prediksi penyakit hipertensi. Dukungan ini memainkan peran kunci dalam kemajuan

dan keberhasilan penelitian kami, dan kami sangat berterima kasih atas komitmen Universitas Nurul Jadid dalam mendukung riset dan pengembangan ilmiah.

## REFERENSI

- [1] S. Moick, I. Sommer, and G. Gartlehner, "WHO Guideline for the Pharmacological Treatment of Hypertension in Adults," *Gesundheitswesen*, vol. 85, no. 2. 2023. doi: 10.1055/a-1989-1745.
- [2] Dr. Tunggul Diapari Situmorang, "Hari Hipertensi Dunia 2019 : 'Know Your Number, Kendalikan Tekanan Darahmu dengan CERDIK.'", *Kemntrian Kesehatan Republik Indonesia*, 2019.
- [3] WHO, "Hipertensi : ' The silent killer ,'" *Harta general*, 2018.
- [4] World Health Organization, "Fact sheet: Cardiovascular diseases (CVDs)," *World Health Organization*, no. May, 2017.
- [5] W. Agustina, Y. Oktafirnanda, and W. Wardiah, "Faktor Risiko yang Berhubungan dengan Kejadian Hipertensi pada Wanita Usia Reproduksi di Wilayah Kerja Puskesmas Langsa Lama Kota Langsa," *Jurnal Bidan Komunitas*, vol. 1, no. 1, 2018, doi: 10.33085/jbk.v1i1.3927.
- [6] J. A. Orozco Torres, A. Medina Santiago, J. M. Villegas Izaguirre, M. Amador García, and A. Delgado Hernández, "Hypertension Diagnosis with Backpropagation Neural Networks for Sustainability in Public Health," *Sensors*, vol. 22, no. 14, 2022, doi: 10.3390/s22145272.
- [7] Elsi Setiandari L.O, "Hubungan Pengetahuan, Pekerjaan dan Genetik (riwayat hipertensi dalam keluarga) Terhadap Perilaku Pencegahan Penyakit Hipertensi," *Media Publikasi Promosi Kesehatan Indonesia (MPPKI)*, vol. 5, no. 4, 2022, doi: 10.56338/mppki.v5i4.2386.
- [8] F. López-Martínez, E. R. Núñez-Valdez, R. G. Crespo, and V. García-Díaz, "An artificial neural network approach for predicting hypertension using NHANES data," *Sci Rep*, vol. 10, no. 1, 2020, doi: 10.1038/s41598-020-67640-z.
- [9] N. Kasim and G. S. Nugraha, "Pengenalan Pola Tulisan Tangan Aksara Arab Menggunakan Metode Convolution Neural Network," *Jurnal Teknologi Informatika, Komputer, dan Aplikasinya (JTika)*, vol. 3, no. 1, 2021, doi: 10.29303/jtika.v3i1.136.
- [10] Y. Tian, Y. Zhang, and H. Zhang, "Recent Advances in Stochastic Gradient Descent in Deep Learning," *Mathematics*, vol. 11, no. 3. 2023. doi: 10.3390/math11030682.
- [11] D. Setiawan, R. N. Putri, and R. Suryanita, "Perbandingan Algoritma Genetika dan Backpropagation pada Aplikasi Prediksi Penyakit Autoimun," *Khazanah Informatika : Jurnal Ilmu Komputer dan Informatika*, vol. 5, no. 1, 2019, doi: 10.23917/khif.v5i1.7173.
- [12] M. Jain, V. Saihjjal, N. Singh, and S. B. Singh, "An Overview of Variants and Advancements of PSO Algorithm," *Applied Sciences (Switzerland)*, vol. 12, no. 17. 2022. doi: 10.3390/app12178392.
- [13] R. Hidayat, R. A. Ronaldo, R. A. Prasetyo, and S. A. Edho Wicaksono, "Optimasi Parameter Support Vector Machine Menggunakan Algoritma Genetika untuk Meningkatkan Prediksi Pergerakan Harga Saham," *COREAI: Jurnal Kecerdasan Buatan, Komputasi dan Teknologi Informatika*, vol. 3, no. 1, 2022, doi: 10.33650/coreai.v3i1.3859.
- [14] A. M. Rizki and A. L. Nurlaili, "Algoritme Particle Swarm Optimization (PSO) untuk Optimasi Perencanaan Produksi Agregat Multi-Site pada Industri Tekstil Rumahan," *Journal of Computer, Electronic, and Telecommunication*, vol. 1, no. 2, 2021, doi: 10.52435/complete.v1i2.73.
- [15] R. Rizaldi and M. A. R. Hariri, "Implementasi Particle Swarm Optimization (PSO) untuk Optimisasi Algoritma Naive Bayes dalam Memprediksi Mahasiswa Lulus Tepat Waktu," *COREAI: Jurnal Kecerdasan Buatan, Komputasi dan Teknologi Informatika*, vol. 2, no. 1, 2021.
- [16] H. Zhu, Y. Wang, K. Wang, and Y. Chen, "Particle Swarm Optimization (PSO) for the constrained portfolio optimization problem," *Expert Syst Appl*, vol. 38, no. 8, 2011, doi: 10.1016/j.eswa.2011.02.075.
- [17] S. Yuhadisi and Suliadi, "Penerapan Metode Modifikasi Hosmer-Lemeshow Test pada Model Regresi Logistik Data Penderita Penyakit Hipertensi," *Prosiding Statistika*, vol. 7, no. 1, 2021.