

BAB II

LANDASAN TEORI

2.1 Landasan Teori

2.1.1 *Monkeypox Virus*


Monkeypox virus (MPXV) adalah *patogen zoonosis* yang termasuk dalam genus *Orthopoxvirus*, menyebabkan penyakit mirip cacar dengan gejala yang lebih ringan dan tingkat kematian lebih rendah (Gong dkk., 2022). MPXV memiliki dua clade utama, yaitu Clade Afrika Tengah dan Clade Afrika Barat, dengan Clade Afrika Tengah memiliki tingkat virulensi yang lebih tinggi (Kannan dkk., 2022). Penularan MPXV dapat terjadi melalui kontak langsung dengan cairan tubuh, lesi kulit, atau droplet pernapasan individu yang terinfeksi. MPXV juga dapat menyebar melalui kontak dengan benda yang terkontaminasi virus, serta kemungkinan adanya transmisi melalui hubungan seksual dan penularan vertikal dari ibu ke janin (Moore dkk., 2023). Faktor lingkungan, pola interaksi manusia dengan hewan liar, serta mobilitas global berkontribusi terhadap penyebaran virus ini ke berbagai wilayah.

Sejak Mei 2022 terjadi peningkatan kasus MPXV secara global, termasuk di negara-negara yang sebelumnya tidak memiliki riwayat endemisitas penyakit ini. Kasus yang terjadi di berbagai benua menyebabkan Organisasi Kesehatan Dunia (WHO) menetapkan wabah MPXV sebagai *Public Health Emergency of International Concern* (PHEIC) atau darurat kesehatan masyarakat yang menjadi perhatian global (Forni dkk., 2022). Meskipun belum terdapat pengobatan spesifik yang ditargetkan untuk MPXV namun penelitian menunjukkan bahwa vaksin cacar yang dikembangkan sebelumnya memiliki efektivitas dalam memberikan

perlindungan terhadap infeksi MPXV. Beberapa obat antivirus seperti *tecovirimat* telah dikaji sebagai terapi potensial dalam menangani kasus MPXV yang parah (Gong dkk., 2022). MPXV memiliki jangkauan inang yang luas, termasuk berbagai spesies hewan liar di Afrika, yang meningkatkan risiko virus ini menetap di populasi hewan sebagai reservoir alami. Keberadaan reservoir hewan ini berpotensi memicu kemunculan kembali wabah MPXV di masa depan. Sehingga diperlukan upaya pemantauan untuk mengidentifikasi serta mengendalikan kemungkinan sumber infeksi baru di daerah endemik maupun non-endemik (Forni dkk., 2022).


Penelitian terkini telah mengeksplorasi penggunaan kecerdasan buatan dalam epidemiologi, terutama dalam memprediksi wabah MPXV. Berbagai model seperti ANN, LSTM, dan GRU, telah diterapkan untuk meramalkan kasus MPXV di berbagai negara (Alnaji, 2024b; Manohar & Das, 2022). Hasil penelitian menunjukkan bahwa model ANN seringkali memberikan akurasi lebih tinggi dibandingkan metode lainnya dalam memprediksi pola penyebaran wabah (Manohar & Das, 2022; Priyadarshini dkk., 2023). Berdasarkan temuan tersebut, penelitian ini berupaya mengoptimalkan metode prediksi berbasis jaringan syaraf untuk mendukung kebijakan mitigasi wabah yang lebih efektif di masa depan.

2.1.2 Artificial Neural Network



Gambar 2.1 *Neuron Biologis menjadi Neuron Buatan (Jaringan Syaraf Tiruan dan Aplikasinya | GeeksforGeeks)*

Artificial Neural Networks merupakan model komputasi yang terinspirasi dari struktur dan fungsi *neuron* biologis dalam otak manusia (Geirhos dkk., 2017). ANN terdiri dari sejumlah *neuron* yang saling terhubung dalam beberapa lapisan, termasuk satu atau lebih *hidden layer* yang menghubungkan *input layer* dan *output layer*. Setiap *neuron* dalam jaringan ini memproses informasi dalam bentuk skalar dan berinteraksi melalui bobot koneksi yang diperbarui selama proses pelatihan untuk meminimalkan kesalahan antara nilai prediksi dan nilai aktual Gambar 2.1 merupakan struktur dari model ANN.



Gambar 2.2 Struktur ANN (Aichouri dkk., 2015)

1. Lapisan Input (*Input Layer*) berfungsi sebagai penghubung jaringan ke dunia luar (sumber data). *Neuron-neuron* ini tidak melakukan apapun pada data, hanya meneruskan data ini ke lapisan berikutnya.
2. Lapisan Tersembunyi (*Hidden Layer*). Suatu jaringan dapat memiliki lebih dari satu hidden layer atau bahkan tidak bisa punya sama sekali. Jika jaringan memiliki beberapa lapisan tersembunyi, maka lapisan tersembunyi paling bawah yang menerima dari input dari input layer.
3. Lapisan Output (*Output Layer*). Prinsip kerja pada lapisan ini sama dengan prinsip kerja pada hidden layer dan ini juga digunakan fungsi *ReLU*. Tetapi keluaran dari lapisan ini sudah dianggap dari keluaran proses.

2.1.3 Optimasi *Hyperparameter*

Hyperparameter adalah variabel yang mempengaruhi *output* dari suatu model dan harus ditentukan terlebih dahulu sebelum proses pelatihan dimulai. Nilai-nilai ini tidak dipelajari oleh model, tetapi ditetapkan secara eksplisit saat perancangan. *hyperparameter tuning* adalah proses sistematis untuk menemukan kombinasi nilai *hyperparameter* yang optimal guna meningkatkan kinerja model *machine learning* atau *deep learning* (Bartz dkk., t.t.). Penelitian ini melakukan *tuning* pada model *Artificial Neural Network* (ANN) untuk memprediksi jumlah kasus cacar monyet global. *Hyperparameter* yang diatur mencakup *learning rate*, jumlah *hidden layer*, jumlah *neuron*, dan *batch size*. Proses tuning dilakukan menggunakan algoritma optimasi *Particle Swarm Optimization* (PSO), *Genetic Algorithm* (GA), dan *Harris Hawks Optimization* (HHO).

2.1.4 *Particle Swarm Optimization (PSO)*

Particle Swarm Optimization (PSO) adalah algoritma optimasi berbasis populasi yang meniru perilaku sosial kawanan dalam mencari solusi optimal. Algoritma ini pertama kali diperkenalkan oleh Kennedy dan Eberhart pada tahun 1995 dan dikembangkan lebih lanjut pada tahun 1997. PSO bekerja dengan memodelkan setiap individu dalam populasi sebagai partikel, yang memperbarui posisi dan kecepatannya berdasarkan pengalaman individu (*personal best* atau *pbest*) serta pengalaman terbaik dari seluruh populasi (*global best* atau *gbest*). Algoritma ini meniru mekanisme koloni dalam menemukan jalur tercepat menuju sumber makanan, sehingga dapat diterapkan dalam berbagai permasalahan komputasi untuk mencari solusi yang efisien (Hasan dkk., 2022). Pergerakan setiap partikel diperbarui berdasarkan kecepatan sebelumnya serta dua komponen utama yaitu eksplorasi individu dan eksplorasi global.

PSO digunakan dalam penelitian ini untuk melakukan *hyperparameter tuning* pada ANN. Pada PSO, setiap partikel mewakili satu kombinasi *hyperparameter* yang diuji. Proses optimasi dilakukan untuk mencari kombinasi *hyperparameter* terbaik yang akan menghasilkan model ANN dengan performansi terbaik. Kombinasi *hyperparameter* tersebut diuji melalui *forward propagation*, dimana model ANN dijalankan dengan *hyperparameter* tersebut untuk menghasilkan prediksi, yang kemudian dievaluasi menggunakan matrik evaluasi RMSE dan R2.

Persamaan (1) merupakan pembaruan kecepatan partikel pada dimensi d , persamaan (2) merupakan pembaruan posisi partikel pada dimensi d dan pada

proses ini *fitness* dihitung dengan melakukan *forward propagation* model ANN dengan kombinasi *hyperparameter* yang diuji, posisi partikel disini mewakili nilai *hyperparameter* baru yang akan digunakan untuk melatih model ANN di iterasi berikutnya. Proses ini digunakan untuk mengevaluasi kualitas model berdasarkan kemampuan prediksinya.

$$v_{i,d}^{t+1} = w v_{i,d}^t + c_1 r_1 (pbest_{i,d} - x_{i,d}^t) + c_2 r_2 (gbest_d - x_{i,d}^t) \quad (1)$$

$$x_{i,d}^{t+1} = x_{i,d}^t + v_{i,d}^{t+1} \quad (2)$$

$$w = W_{max} - \frac{(W_{max} - W_{min}) \times iter}{iter_{max}} \quad (3)$$

dimana :

$v_{i,d}^{t+1}$: kecepatan partikel ke- i pada dimensi d di iterasi t

$x_{i,d}^{t+1}$: posisi partikel ke- i pada dimensi d

$pbest_{i,d}$: posisi terbaik individu

$gbest_d$: posisi terbaik global

$c_1 c_2$: faktor pembelajaran

$r_1 r_2$: bilangan acak dalam rentang $[0,1]$


w : bobot inersia

Langkah-langkah optimasi ANN menggunakan PSO:

1. Menentukan struktur ANN yang akan dioptimasi.
2. Menentukan parameter PSO seperti jumlah partikel, ukuran populasi, bobot inersia, kecepatan awal, faktor pembelajaran c_1 dan c_2 .
3. Menghitung nilai *fitness* dengan memanfaatkan data pelatihan melalui *forward propagation* pada model ANN yang dijalankan menggunakan kombinasi *hyperparameter* yang diuji.

4. Memperbarui solusi terbaik individu ($pbest$) dan global ($gbest$) serta kecepatan dan posisi partikel.
5. Mengulangi langkah 3 hingga kondisi penghentian terpenuhi.
6. Menyimpan nilai terbaik sebagai solusi optimal setelah iterasi selesai

Setelah selesai, kombinasi *hyperparameter* terbaik ditemukan model ANN dilatih kembali untuk memperbarui bobot model. PSO digunakan dalam algoritma yang digambarkan pada Gambar 2.3 (a) untuk mengeksplorasi nilai bobot optimal untuk model ANN yang dirancang.




Gambar 2.3 Diagram alir algoritma (a) ANN-PSO (b) ANN-HHO dan (c) ANN-GA

2.1.5 Harris Hawks Optimization (HHO)

Algoritma *Harris Hawks Optimization* (HHO) adalah algoritma optimasi berbasis populasi yang terinspirasi oleh perilaku berburu elang Harris (*Parabuteo unicinctus*). Algoritma ini terdiri dari dua fase utama yaitu eksplorasi dan eksploitasi. Proses optimasi dilakukan melalui pembaruan posisi elang yang disesuaikan berdasarkan strategi berburu yang digunakan, yang secara matematis dioptimalkan untuk memaksimalkan hasil pencarian solusi terbaik.

Fase eksplorasi, elang mencari solusi dengan menggunakan dua strategi berdasarkan nilai acak q . Jika nilai $q \geq 0.5$, elang bertengger dekat individu lain untuk memperluas pencarian. Jika $q < 0.5$, elang memilih lokasi acak untuk mengeksplorasi lebih jauh. Fase eksplorasi ini bertujuan untuk memperluas pencarian solusi, sedangkan fase eksploitasi digunakan ketika energi $|E| < 1$, dimana elang akan berfokus pada solusi terbaik yang ditemukan. Strategi ini dimodelkan dalam Persamaan (4) dan (5) dan Gambar 2.2 menunjukkan fase algoritma optimasi HHO.



Gambar 2.4 Fase Algoritma Optimasi HHO (Heidari dkk., 2019a)

$$\begin{aligned}
& X(t+1) \\
&= \begin{cases} X_{rand}(t) - r_1 |X_{rand}(t) - 2r_2 X(t)|, & q \geq 0.5 \\ (X_{rabbit}(t) - X_m(t)) - r_3(LB + r_4(UB - LB)), & q < 0.5 \end{cases} \quad (4)
\end{aligned}$$

dimana :

X_{rand} : Posisi acak dalam ruang pencarian

X_{rabbit} : Posisi terbaik yang ditemukan (mangsa)

X_m : posisi rata-rata populasi elang

LB, UB : Batas bawah dan atas pencarian

r_1, r_2, r_3, r_4, q : Parameter acak dalam interval $[0,1]$

Posisi rata-rata elang dihitung dalam interval $[0,1]$

$$X_m(t) = \frac{1}{N} \sum_{i=1}^N x_i(t) \quad (5)$$

dengan N adalah jumlah total populasi elang.

Selanjutnya Fase eksploitasi dilakukan saat energi E memenuhi $|E| < 1$. Nilai energi dihitung sebagai berikut: menggunakan persamaan (6).

$$E = 2E_0 \left(1 - \frac{t}{T}\right) \quad (6)$$

t adalah iterasi saat ini dan T adalah jumlah iterasi maksimum. T dan E_0 bernilai antara -1 hingga 1, menunjukkan bahwa energi mangsa berkurang saat melarikan diri. Jika $|E| \geq 1$, elang mencari wilayah baru (eksplorasi), sedangkan jika $|E| < 1$, mereka mengeksploitasi lingkungan solusi yang ada. Saat $|E| \geq 0.5$, mangsa masih dapat melarikan diri, sehingga diterapkan *soft besiege*. Jika $|E| < 0.5$, mangsa terlalu lelah untuk kabur, sehingga elang Harris menerapkan *hard besiege* dengan ketat sebelum melakukan serangan akhir. Iterasi berlanjut hingga kondisi penghentian


terpenuhi, seperti jumlah iterasi maksimum atau konvergensi solusi terbaik. Hasil akhirnya adalah lokasi terbaik yang ditemukan oleh sang elang dan nilai *fitness* yang terkait (Heidari dkk., 2019b).

Langkah-langkah optimasi ANN menggunakan HHO:

1. Inisialisasi posisi dan kecepatan elang (solusi awal), dimana setiap elang merepresentasikan kandidat solusi, yaitu kombinasi *hyperparameter* model ANN yang akan dieksplorasi.
2. Menghitung nilai *fitness* setiap elang (solusi) berdasarkan performa model ANN yang diterapkan pada data pelatihan.
3. Identifikasi solusi terbaik (mangsa) yang dipilih berdasarkan nilai *fitness* yang paling baik.
4. Menghitung energi (E) dan menentukan strategi eksploitasi atau eksplorasi. Energi dihitung untuk menentukan apakah elang harus terus mengeksplorasi solusi baru atau mengeksploitasi solusi yang sudah ditemukan.
5. Memperbarui posisi elang berdasarkan strategi yang dipilih (eksplorasi atau eksploitasi) untuk mencari solusi yang lebih baik.
6. Proses ini diulang selama beberapa iterasi sampai kondisi penghentian tercapai

Penggunaan HHO memungkinkan proses optimasi model ANN dapat diperbaiki secara iteratif untuk menemukan kombinasi *hyperparameter* yang menghasilkan model dengan performa terbaik, seperti yang terlihat pada Gambar 2.3 (b)

2.1.6 Genetic Algorithm (GA)



Gambar 2.5 Proses algoritma Genetika (Kholik dkk., 2018)

Genetic Algorithm (GA) adalah algoritma optimasi evolusioner yang terinspirasi dari teori evolusi alami Darwin, yang menekankan seleksi alam (Hassanat dkk., 2019). GA digunakan untuk mengeksplorasi ruang solusi suatu permasalahan melalui tahapan evolusioner seperti seleksi, *crossover*, dan mutasi guna memperoleh solusi terbaik.

Tahapan GA dimulai dari pembentukan kromosom dan populasi. Kromosom merepresentasikan solusi potensial dalam bentuk gen, yang dapat berupa bilangan biner, *real*, atau permutasi. Sekumpulan kromosom membentuk populasi, dan jumlah populasi ditentukan oleh parameter awal. Setiap kromosom kemudian dievaluasi menggunakan fungsi *fitness* untuk menilai seberapa baik solusi tersebut dalam menyelesaikan masalah dimana semakin tinggi nilai *fitness*, semakin baik solusi.

Selanjutnya, dua kromosom terbaik dipilih melalui proses seleksi *parent* untuk direproduksi. Proses reproduksi ini meliputi *crossover*, yaitu penggabungan dua parent untuk menghasilkan offspring baru, serta mutasi, yang mengubah nilai gen secara acak guna menjaga keberagaman solusi. Tahapan berikutnya adalah

seleksi survivor, yaitu pemilihan individu terbaik dari populasi sebelumnya dan offspring untuk membentuk generasi baru. Proses ini berulang hingga solusi optimal tercapai, *fitness* mengalami konvergensi, atau iterasi mencapai batas maksimum (Kholik dkk., 2018).

Penelitian ini menggunakan algoritma GA untuk optimasi *hyperparameter* yang bertujuan untuk mencari kombinasi terbaik dari *hyperparameter* seperti jumlah *neuron*, jumlah lapisan tersembunyi, *batch size*, dan *learning rate*. Setiap individu dalam populasi GA merepresentasikan satu kombinasi *hyperparameter* yang dapat mempengaruhi performa model ANN.

Langkah-langkah optimasi ANN menggunakan GA:

1. Inisialisasi populasi dengan membuat populasi awal yang terdiri dari sejumlah individu, dimana setiap individu direpresentasikan oleh kromosom yang menyimpan nilai-nilai untuk *hyperparameter* model ANN.
2. Evaluasi *fitness* untuk setiap individu (kromosom) berdasarkan performa model ANN yang dihasilkan oleh kombinasi *hyperparameter* tersebut. Proses ini menggunakan matrik evaluasi RMSE dan R^2 .
3. Melakukan seleksi untuk memilih individu-individu dengan *fitness* terbaik, individu dengan fitness yang lebih tinggi memiliki peluang lebih besar untuk dipilih dan bereproduksi.
4. Setelah seleksi dilakukan *crossover* yaitu proses menggabungkan dua individu (kromosom) untuk menghasilkan individu baru. *Crossover* bertujuan untuk mengkombinasikan karakteristik terbaik dari kedua individu sehingga diharapkan menghasilkan solusi yang lebih baik.

5. Selanjutnya proses mutasi diterapkan pada individu-individu baru dengan kemungkinan tertentu. Mutasi mengubah nilai dari beberapa parameter dalam kromosom untuk memperkenalkan variasi dan menghindari konvergensi pada solusi lokal.
6. Proses reproduksi menghasilkan individu baru yang merupakan hasil dari *crossover* dan mutasi. Individu baru ini kemudian diproses lebih lanjut dalam generasi berikutnya.
7. Dilakukan evaluasi dan iterasi pada setiap generasi untuk terus memperbaiki kualitas solusi. Proses ini berlanjut hingga tercapai kondisi penghentian yang ditentukan.
8. Setelah iterasi selesai, individu dengan *fitness* terbaik dipilih sebagai solusi optimal yang menghasilkan model ANN dengan kombinasi *hyperparameter* terbaik.

Tahapan algoritma GA dalam mengoptimasi ANN secara grafis diperlihatkan pada Gambar 2.3 (c).

Ketiga algoritma *metaheuristik* tersebut memiliki pendekatan dan karakteristik yang berbeda dalam proses optimasi. Perbedaan mencakup inspirasi biologis, mekanisme pembaruan solusi, serta parameter-parameter utama yang mempengaruhi kinerja. Tabel 2.1 berikut menyajikan ringkasan perbandingan antara algoritma secara konseptual untuk memberikan pemahaman intuitif terhadap peran masing-masing dalam proses optimasi model

Tabel 2.1 Perbandingan Tiga Algoritma Optimasi *Metaheuristic*

Aspek	GA (Hassanat dkk., 2019)	PSO (Hasan dkk., 2022)	HHO (Heidari dkk., 2019)
Inspirasi Biologis	Evolusi genetika dan seleksi alam	Perilaku sosial kawanan burung atau ikan	Strategi berburu elang Harris
Representasi Solusi	Kromosom (<i>string biner/real</i>)	Partikel dengan posisi dan kecepatan	Agen (<i>hawk</i>) dengan posisi dalam ruang pencarian
Operator Utama	Seleksi, <i>crossover</i> , mutasi	Pembaruan kecepatan dan posisi berdasarkan tetangga	Pergantian strategi eksplorasi dan eksploitasi adaptif
Kelebihan	Baik dalam menjelajahi ruang solusi yang kompleks	Cepat konvergen dan mudah diimplementasikan	Keseimbangan eksplorasi dan eksploitasi yang adaptif
Kekurangan	Potensi stagnasi atau konvergensi prematur	Rentan terjebak pada solusi lokal	Sensitif terhadap parameter dan iterasi
Parameter Kunci	Ukuran populasi, laju <i>crossover</i> , laju mutasi	Ukuran <i>swarm</i> , konstanta pembelajaran, kecepatan inersia	Jumlah agen, strategi dinamis, parameter energi

2.2 Penelitian Terkait

2.2.1 *State of The Art*

Beberapa penelitian menunjukkan peran penting ANN dalam memprediksi kasus penyakit menular, termasuk MPXV. Temuan tersebut memperkuat pengembangan model prediktif yang lebih akurat untuk mendukung mitigasi wabah. Tabel 2.1 merangkum penelitian terkait yang menjadi dasar penelitian in

Tabel 2.2 State of Art

No	Judul	Peneliti	Algoritma	Hasil Penelitian
1.	An Optimized Neural Network Using Genetic Algorithm for Cardiovascular Disease Prediction	(Arroyo & Delima, 2022)	ANN-GA	Mengoptimalkan ANN menggunakan Algoritma Genetika (GA) untuk meningkatkan akurasi prediksi penyakit kardiovaskular, mencapai tingkat akurasi 73,43% dan mengungguli algoritma pembelajaran mesin lainnya.
2.	Perbandingan Metode ANN-PSO dan ANN-GA untuk Perbandingan Akurasi Prediksi Harga Emas Antam	(Annisa Maori, 2019)	ANN-PSO, ANN-GA	Penelitian ini mengevaluasi prediksi harga emas Antam menggunakan Backpropagation <i>Artificial Neural Network</i> (ANN) yang dioptimalkan dengan Particle Swarm Optimization (PSO) dan Genetic Algorithm (GA), dan menemukan bahwa PSO memberikan nilai RMSE yang lebih baik yaitu 0,026 dibandingkan dengan GA sebesar 0,09, yang menunjukkan kinerja yang lebih baik dalam memprediksi harga emas.
3.	Penerapan Prediksi Produksi Padi Menggunakan <i>Artificial Neural Network</i> Algoritma Backpropagation	(Putra & Ulfa Walmi, 2020)	ANN	Penelitian ini berhasil merancang dan menerapkan ANN menggunakan algoritma backpropagation untuk memprediksi produksi padi di Sumatera Barat, Indonesia, mencapai akurasi 88,14% dan tingkat kesalahan 11,86%.

No	Judul	Peneliti	Algoritma	Hasil Penelitian
4.	Air Quality Prediction Using Improved PSO-BP Neural Network	(Huang dkk., 2020)	ANN-PSO	Penelitian ini mengusulkan algoritma optimasi kelompok partikel (PSO) yang ditingkatkan untuk mengoptimalkan jaringan syaraf perambatan balik (BP) dalam memprediksi Indeks Kualitas Udara (AQI), sehingga mencapai akurasi yang lebih tinggi dibandingkan dengan model lainnya yaitu sebesar sebesar 99,03%
5.	Residential Load Time Series Forecasting using ANN and Classical Methods	(Chandran dkk., 2021)	ANN, ARIMA, ARIMAX	Model ANN 2L-12N dengan fungsi aktivasi tan-sigmoid menunjukkan performa terbaik dalam meramalkan beban listrik rumah tangga. Nilai RMSE pada berbagai periode peramalan adalah 1 jam 1.6453, 12 jam 0.4807, 1 hari 0.3485 dan 1 minggu 0.3568.
6.	Machine Learning In Epidemiology: Neural Networks Forecasting Of Monkeypox Cases	(Alnaji, 2024b)	ANN, LSTM dan GRU	Penelitian ini membandingkan ANN, LSTM, dan GRU dalam memprediksi penyebaran monkeypox menggunakan dataset dari Our World in Data. Hasilnya, ANN menunjukkan performa terbaik dengan RMSE sebesar 12,34 dan R^2 sebesar 0,92.
7.	Enhanced <i>Artificial Neural Network</i> with Harris Hawks Optimization for Predicting	(Sammen dkk., 2020)	ANN, ANN-HHO, ANN-PSO, ANN-GA	Studi ini menggunakan metode alternatif untuk memperkirakan kedalaman gerusan di bagian hilir spillway ski-jump, dengan menggunakan model hibrida (ANN-HHO, ANN-PSO, ANN-GA)

No	Judul	Peneliti	Algoritma	Hasil Penelitian
	Scour Depth Downstream of Ski-Jump Spillway			dan model ANN tradisional, dengan ANN-HHO menunjukkan kinerja terbaik dalam hal akurasi dan keandalan yaitu dengan $MAE = 0,1760$ m dan $RMSE = 0,2538$ m.
8.	Commercial Building Load Forecasts with <i>Artificial Neural Network</i>	(Jing dkk., 2019)	ANN dengan Tiga algoritma pelatihan dievaluasi, yaitu Levenberg-Marquardt, Scaled Conjugate Gradient, dan Bayesian Regularization	Penelitian ini membahas metode prediksi beban listrik per jam menggunakan <i>Artificial Neural Network</i> (ANN) dengan memasukkan titik setel HVAC, beban historis, dan data cuaca luar sebagai input. Tiga algoritma pelatihan dievaluasi, yaitu Levenberg-Marquardt, Scaled Conjugate Gradient, dan Bayesian Regularization. Hasil menunjukkan bahwa model dengan Bayesian Regularization memiliki akurasi terbaik, dengan kesalahan prediksi sekitar 5% untuk prediksi satu jam ke depan dan 8% untuk dua belas jam ke depan. Studi kasus dilakukan pada sebuah gedung komersial di Chicago.
9.	Komparasi Metode ANN-PSO dan ANN-GA Tuberkulosis	(Mutiara dkk., t.t.)	ANN-PSO, ANN-GA	Penelitian ini membandingkan penggunaan metode Jaringan Syaraf Tiruan (JST) dengan Particle Swarm Optimization (PSO) dan Algoritma Genetika (GA) untuk meningkatkan akurasi

No	Judul	Peneliti	Algoritma	Hasil Penelitian
				prediksi tuberkulosis, dan menemukan bahwa GA dengan JST memberikan akurasi tertinggi sebesar 96,55%.
10.	Optimasi Jaringan Syaraf Tiruan Backpropagation Dengan Particle Swarm Optimization Untuk Prediksi Pasang Surut Air Laut	(Nikentari dkk., 2018)	ANN-PSO	Penelitian ini menggunakan Particle Swarm Optimization dan Jaringan Syaraf Tiruan untuk memprediksi tingkat pasang surut di Indonesia dengan akurasi prediksi sebesar 91,56% yang dapat memperlancar berbagai aktivitas laut.
11.	A Comprehensive Analysis Of The <i>Artificial Neural Networks</i> Model For Predicting Monkeypox Outbreaks	(Alnaji, 2024a)	ANN	Penelitian ini mengembangkan model ANN untuk memprediksi penyebaran monkeypox berdasarkan data dari berbagai negara. Dataset yang digunakan diperoleh dari <i>Our World in Data</i> , yang mencakup kasus terkonfirmasi di Argentina, Brazil, Perancis, Jerman, Chili, dan Meksiko. Hasil evaluasi menunjukkan bahwa model ANN memiliki RMSE sebesar 1.00 pada dataset Argentina dengan R^2 mencapai 94.71%, menunjukkan akurasi tinggi dalam meramalkan tren kasus.

No	Judul	Peneliti	Algoritma	Hasil Penelitian
12.	Peramalan Beban Jangka Panjang Sistem Kelistrikan Kota Bandung Menggunakan ANN	(Barokah & Harahap, 2024)	ANN	Penelitian ini bertujuan untuk memprediksi beban listrik jangka panjang kota Bandung untuk tahun 2022 dan 2023 berdasarkan data historis dari tahun 1999–2021. Model ANN dengan arsitektur <i>feedforward</i> dan algoritma <i>backpropagation</i> . Hasil evaluasi menunjukkan MAPE 0.3976% RMSE 0.0120 dan R ² 0.9892. Model ini terbukti memiliki akurasi tinggi dan stabil dalam peramalan beban listrik.
13.	Model <i>Artificial Neural Network</i> Berbasis Particle Swarm Optimization untuk Prediksi Laju Inflasi	(Raharjo, 2019)	ANN-PSO	Model PSO-ANN, yaitu integrasi antara <i>Artificial Neural Network</i> (ANN) dan Particle Swarm Optimization berbasis pembobotan atribut, terbukti lebih akurat dalam memprediksi laju inflasi dibanding ANN standar. Hasil pengujian menunjukkan nilai RMSE sebesar 0,157 pada PSO-ANN, lebih baik dibanding ANN tanpa optimasi yang menghasilkan RMSE 0,181.
14.	Prediksi Jumlah Produksi Air PDAM Menggunakan Metode ANN dengan Optimasi PSO	(Akrom.A dkk., 2021)	ANN-PSO	Model prediksi volume produksi air PDAM Kota Semarang dikembangkan menggunakan <i>Artificial Neural Network</i> yang dioptimasi dengan Particle Swarm Optimization (ANN-PSO). Hasil evaluasi menunjukkan bahwa ANN-PSO memberikan

No	Judul	Peneliti	Algoritma	Hasil Penelitian
				akurasi lebih tinggi dibanding ANN biasa, dengan nilai RMSE sebesar 3,797, lebih rendah daripada ANN tanpa optimasi yang menghasilkan RMSE 4,943.
15.	Implementasi Algoritma Genetika dan Neural Network pada Aplikasi Peramalan Produksi Mie	(Kusnadi & Pratama, 2017)	ANN-GA	Penelitian ini mengembangkan aplikasi prediksi jumlah produksi menggunakan kombinasi Neural Network dan Genetic Algorithm. Genetic Algorithm digunakan untuk mengoptimasi bobot jaringan. Arsitektur jaringan terdiri dari 12 input, serta tiga hidden layer dengan 5, 3, dan 3 <i>neuron</i> . Dengan 10 individu, 50 generasi, probabilitas crossover 0,8 dan mutasi 0,1, model mencapai akurasi prediksi sebesar 86%.

Berbagai penelitian sebelumnya menunjukkan bahwa integrasi antara ANN dan algoritma optimasi seperti *Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO), dan *Harris Hawks Optimization* (HHO) mampu meningkatkan performa prediksi pada berbagai domain (Arroyo & Delima, 2022). berhasil mengoptimasi ANN menggunakan GA untuk prediksi penyakit kardiovaskular dengan akurasi 73,43%, sementara (Annisa Maori, 2019) melaporkan PSO lebih unggul dari GA dalam memprediksi harga emas dengan nilai RMSE lebih kecil. Studi (Huang dkk., 2020) menunjukkan peningkatan akurasi prediksi kualitas udara menggunakan PSO-BP Neural Network, mencapai akurasi 99,03%. Untuk prediksi kasus penyakit, model hybrid ANN-GA maupun ANN-PSO juga banyak diterapkan, seperti pada studi tuberkulosis (Mutiar dkk., t.t.), Covid-19 (Kurniati dkk., 2024), dan bahkan prediksi produksi mie (Kusnadi & Pratama, 2017). Secara khusus, penelitian (Alnaji, 2024a, 2024b) yang menjadi rujukan utama penelitian ini, membandingkan model ANN, LSTM, dan GRU untuk prediksi kasus Monkeypox dan menemukan bahwa ANN memiliki performa terbaik. Temuan-temuan ini menegaskan bahwa penggunaan algoritma optimasi dalam memaksimalkan performa ANN bukan hanya relevan, tetapi juga efektif untuk diaplikasikan dalam kasus prediksi epidemi seperti Monkeypox.

Meskipun berbagai studi telah menunjukkan efektivitas ANN dan metode optimasi dalam berbagai domain, hingga saat ini belum terdapat penelitian yang secara komprehensif menguji dan membandingkan efektivitas tiga algoritma optimasi sekaligus—yakni GA, PSO, dan HHO—dalam tuning *hyperparameter* ANN untuk prediksi kasus Monkeypox berbasis dataset global dan rentang waktu

yang panjang. Beberapa studi juga masih terbatas pada ruang lingkup regional atau nasional, serta menggunakan data yang kurang representatif terhadap dinamika penyebaran global MPXV. Penelitian ini menjawab kesenjangan tersebut dengan merancang model prediktif berbasis ANN yang dioptimasi menggunakan algoritma PSO, HHO dan GA, serta menguji performanya menggunakan matrik akurasi RMSE dan R^2 . Pendekatan ini diharapkan dapat memberikan kontribusi signifikan terhadap pengembangan sistem prediksi epidemi yang lebih akurat, adaptif, dan mendukung pengambilan kebijakan kesehatan masyarakat di masa mendatang.

2.2.2 Matriks Penelitian

Tabel 2.2 berikut menyajikan matriks penelitian terdahulu yang relevan dengan topik prediksi *berbasis Artificial Neural Network* (ANN)

Tabel 2.3 Matriks Penelitian

No	Judul	Penulis	Model	Optimasi			Evaluasi	
				HHO	PSO	GA	R2	RMSE
1	An Optimized Neural Network Using Genetic Algorithm for Cardiovascular Disease Prediction	(Arroyo & Delima, 2022)	ANN	-	√	√	√	-
2	Perbandingan Metode ANN-PSO dan ANN-GA untuk Perbandingan Akurasi Prediksi Harga Emas Antam	(Annisa Maori, 2019)	ANN	-	-	√	-	√
3	Penerapan Prediksi Produksi Padi Menggunakan <i>Artificial Neural Network</i> Algoritma Backpropagation	(Putra & Ulfa Walmi, 2020)	ANN	-	-	-	√	√
4	Air Quality Prediction Using Improved PSO-BP Neural Network	(Huang dkk., 2020)	ANN		√		-	√
5	Residential Load Time Series Forecasting using ANN and Classical Methods	(Fadilah dkk., 2024)	ANN, ARIMA, ARIMAX	-	-	-		√
6	Machine Learning In Epidemiology: Neural Networks Forecasting Of Monkeypox Cases	(Alnaji, 2024b)	ANN, LSTM dan GRU	-	-	-	√	√
7	Enhanced <i>Artificial Neural Network</i> with Harris Hawks Optimization for Predicting Scour Depth Downstream of Ski-Jump Spillway	(Sammen dkk., 2020)	ANN	√	√	√	-	√

No	Judul	Penulis	Model	Optimasi			Evaluasi	
				HHO	PSO	GA	R2	RMSE
8	Commercial Building Load Forecasts with <i>Artificial Neural Network</i>	(Jing dkk., 2019)	ANN	-	-	-	-	√
9	Komparasi Metode ANN-PSO dan ANN-GA Tuberkulosis	(Mutiara dkk., t.t.)	ANN	-	√	√	√	-
10	Optimasi Jaringan Syaraf Tiruan Backpropagation Dengan Particle Swarm Optimization Untuk Prediksi Pasang Surut Air Laut	(Nikentari dkk., 2018)	ANN	-	√	-	√	-
11	A Comprehensive Analysis Of The <i>Artificial Neural Networks</i> Model For Predicting Monkeypox Outbreaks	(Alnaji, 2024a)	ANN	-	-	-	√	√
12	Peramalan Beban Jangka Panjang Sistem Kelistrikan Kota Bandung Menggunakan ANN	(Barokah & Harahap, 2024)	ANN	-	-	-	√	√
13	Model <i>Artificial Neural Network</i> Berbasis Particle Swarm Optimization untuk Prediksi Laju Inflasi	(Raharjo, 2019)	ANN	-	√	-	-	√
14	Prediksi Jumlah Produksi Air PDAM Menggunakan Metode ANN dengan Optimasi PSO	(Akrom.A dkk., 2021)	ANN	-	√	-	-	√
15	Implementasi Algoritma Genetika dan Neural Network pada Aplikasi Peramalan Produksi Mie	(Kusnadi & Pratama, 2017)	ANN	-	-	√	√	-
16	Analisis Komparasi Algoritma Optimasi Dalam Meningkatkan Akurasi Prediksi Model ANN pada Tren Kasus Cacar Monyet Global	Penelitian ini	ANN	√	√	√	√	√