

# PERBANDINGAN PARTICLE SWARM OPTIMIZATION DAN NGUYEN WIDROW PADA IMPLEMENTASI BACKPROPAGATION UNTUK PREDIKSI JUMLAH KASUS DEMAM BERDARAH DENGUE (STUDI KASUS: DKI JAKARTA)

Audrey Era Goldenia<sup>1</sup>, Didit Widiyanto<sup>2</sup>, Mayanda Mega Santoni<sup>3</sup>,  
Program Studi Informatika, Fakultas Ilmu Komputer,  
Universitas Pembangunan Nasional "Veteran" Jakarta  
Jl. R.S Fatmawati No. 1, Jakarta Selatan  
audreyeg@upnvj.ac.id

**Abstrak.** Demam berdarah dengue merupakan salah satu penyakit berbahaya dan akibat fatal jika tidak ditangani secara cepat dan tepat. Kasus demam berdarah di Indonesia sendiri masih menjadi hal yang perlu diperhatikan dikarenakan banyak kasus yang terjadi di setiap tahunnya yang menyentuh angka ratusan ribu. Untuk mengantisipasi adanya lonjakan kasus yang tiba-tiba dapat memanfaatkan teknologi machine learning guna memprediksi jumlah kasus di masa mendatang. Dalam hal prediksi metode yang dapat digunakan salah satunya yaitu Backpropagation. Untuk mengoptimalkan nilai bobot awal yang akan digunakan dalam jaringan Backpropagation dapat mengombinasikan Backpropagation dengan metode Particle Swarm Optimization dan Nguyen Widrow. Hasil dari penerapan ketiga model didapatkan bahwa model tersebut dapat bekerja dengan baik untuk memprediksi kasus demam berdarah dengan nilai MSE testing yang didapatkan untuk BP, PSO-BP, dan NW-BP adalah  $4.76 \times 10^{-2}$ ,  $4.44 \times 10^{-2}$ ,  $5.70 \times 10^{-2}$ . Dari ketiga model, hasil performa terbaik didapatkan PSO-Backpropagation dengan nilai MSE dan MAPE yaitu  $4.44 \times 10^{-2}$  dan 18.43%.

**Kata Kunci:** *Backpropagation, particle swarm optimization, dbd, demam berdarah dengue, Nguyen-widrow*

## 1. Pendahuluan

### 1.1. Latar Belakang

Demam berdarah *dengue* merupakan penyakit yang bersumber dari suatu virus yang disebut dengan virus dengue yang berasal dari nyamuk *Aedes Spp* [1]. DBD telah menyebar dengan cepat dan menjadi endemik pada lebih dari 100 negara subtropis dan tropis di kawasan Amerika, Afrika, dan Asia Pasifik [2]. Menurut [3], dalam dua dekade terakhir hingga kini, jumlah kasus demam berdarah di dunia terus meningkat hingga lebih dari 8 kali lipat. Pada tahun 2000 terdapat 505.430 kasus dan meningkat pada tahun 2010 menjadi lebih dari 2.4 juta kasus. Selain itu, pada tahun 2019, kasus demam berdarah yang dilaporkan yaitu sebanyak 5.2 juta. Di Indonesia sendiri, kasus demam berdarah *dengue* merupakan permasalahan kesehatan yang sudah dialami masyarakat sejak tahun 1968 [4]. Pola perkembangan kasus demam berdarah yang terjadi Indonesia mengalami kenaikan dan penurunan, dimana pada tahun 2014 hingga 2016 terjadi kenaikan jumlah kasus dan kemudian terjadi penurunan pada tahun 2017 [5]. Salah satu teknologi yang dapat dimanfaatkan untuk mengantisipasi kenaikan dan penurunan jumlah kasus DBD yang tidak pasti adalah *machine learning* yang bisa digunakan untuk membuat model prediksi. Pemodelan prediksi yang dapat digunakan yaitu *Backpropagation Neural Network*. Untuk mengoptimalkan nilai bobot awal dapat menggunakan *Particle Swarm Optimization* dan *Nguyen Widrow*. Adapun tujuan dari penelitian ini untuk mengetahui perbandingan performa *Backpropagation*, *PSO-Backpropagation*, dan

Nguyen Widrow-Backpropagation dalam memprediksi jumlah kasus demam berdarah dengue.

## 2. Landasan Teori

### 2.1. Jaringan Saraf Tiruan

Menurut[6], Jaringan Saraf Tiruan (JST) merupakan pemodelan yang berbentuk jaringan bertujuan untuk menyelesaikan masalah yang rumit dan tidak linear serta sulit untuk dilakukan pemodelan matematis.

Dalam prosesnya, JST memiliki neuron sebagai unit pemroses informasi yang sangat penting dalam operasi suatu jaringan. Pola informasi input dan output yang diterima jaringan akan diproses dalam neuron yang terkumpul dalam lapisan - lapisan. Lapisan penyusun JST antara lain, yaitu :


- Lapisan input, yaitu lapisan yang menerima pola inputan dari luar yang menggambarkan suatu permasalahan.
- Lapisan tersembunyi, yaitu lapisan yang outputnya tidak dapat terlihat.
- Lapisan output, yaitu lapisan yang merupakan solusi dari suatu permasalahan.

#### 2.1.1 Arsitektur Jaringan Saraf Tiruan

Berikut adalah beberapa arsitektur jaringan yang sering digunakan, diantaranya[6]:

- Jaringan layur tunggal (single layer network)

Single layer network merupakan jaringan yang memiliki lapisan tunggal dimana terdiri dari 1 layer input dan 1 layer output. Neuron pada lapisan input selalu terhubung dengan tiap neuron pada lapisan output. Arsitektur single layer network ditunjukkan pada Gambar 2.1.




Gambar 2. 1 Single layer network

Sumber [6]

- Jaringan layur jamak (multi layer network)


Multi layer network merupakan jaringan yang memiliki 3 lapisan, diantaranya: lapisan input (input layer), lapisan tersembunyi (hidden layer), dan lapisan output (output layer). Arsitektur hidden layer network ditunjukkan pada Gambar 2.2.



Gambar 2. 2 Multi Layer Network

Sumber [6]

- c. Jaringan dengan lapisan kompetitif (competitive layer network)  
 Dalam jaringan ini, para neuron bersaing satu sama lain untuk menjadi aktif. Contoh algoritma yang menggunakan jaringan ini yaitu LVQ. Arsitektur single layer network ditunjukkan pada Gambar 2.3.




Gambar 2. 3 Competitive layer network

Sumber [6]

### 2.2. Backpropagation

Algoritma Backpropagation pertama kali dirumuskan oleh Werbos dan kemudian dipopulerkan oleh Rumelhart dan McClelland sebagai algoritma pembelajaran dalam jaringan syaraf tiruan [7]. Dalam proses pembelajarannya, bobot - bobot jaringan saraf tiruan disesuaikan dengan arah mundur berdasarkan nilai error yang didapat sesuai dengan pembelajaran yang dilakukan [8].

Backpropagation merupakan jaringan yang mempunyai unit - unit yang berada dalam satu atau lebih lapisan tersembunyi. Gambar 2.4 dibawah menunjukkan arsitektur backpropagation sebanyak n buah input dan terdiri dari lapisan input, lapisan tersembunyi, serta lapisan.



Gambar 2. 4 Arsitektur Jaringan Backpropagation

Sumber [6]

### 2.3. Particle Swarm Optimization

Particle Swarm Optimization ditemukan pertama kali pada tahun 1995 oleh James Kennedy dan Eberhart[8]. Particle Swarm Optimization (PSO) merupakan salah satu algoritma optimasi yang telah dikenal secara luas dan terinspirasi dari interaksi sekawanan burung[9]. Interaksi sosial yang dimaksud yaitu adanya pengaruh dari satu individu dengan individu - individu lain dalam suatu kelompok. Arti partikel dalam algoritma PSO mengacu pada seekor burung yang berada diantara kawanan burung. Untuk menuju ke sumber makanannya, tiap - tiap individu akan memanfaatkan pengetahuannya masing - masing dalam mencari jalan terbaik. Apabila satu individu telah menemukan jalan terbaik, maka sekawanan burung lainnya akan menuju jalan tersebut[10].

Menurut[10] mengenai perilaku burung dalam kelompoknya, meskipun dalam kecerdasannya setiap burung memiliki keterbatasan tertentu, namun kebiasaan dari seekor burung akan mengikuti rule berikut:

1. Jarak antara satu burung dengan burung lainnya tidak terlalu dekat
2. Arah terbang burung akan menyesuaikan dengan kecepatan burung secara keseluruhan
3. Setiap burung menempatkan dirinya pada posisi rata-rata burung lain dan memberikan jarak yang tidak terlalu jauh dengan kawanan burung lain

Berdasarkan perilaku tersebut, maka dikembangkan model Particle Swarm Optimization seperti dibawah ini:

1. Dalam mendekati targetnya atau sumber makanannya ataupun fungsi tujuan maksimum/minimum, seekor burung akan menginformasikan dengan cepat kepada burung lainnya dalam kawanan tertentu.
2. Burung lainnya akan merespon informasi tersebut dengan mengikuti ke arah target namun secara tidak langsung
3. Adanya peranan komponen tertentu dalam pikiran setiap burung yaitu mengenai apa yang telah dilewatinya di masa lalu

#### 2.4. *Nguyen Widrow*

Nguyen-Widrow merupakan metode yang berfungsi untuk melakukan inialisasi nilai bobot awal pada jaringan saraf tiruan Backpropagation. Dalam menginisialisasi nilai bobot awal dari suatu jaringan dilakukan proses modifikasi nilai tersebut dengan menggunakan bilangan yang berada pada skala dengan jangkauan interval tertentu. Adapun penerapan algoritma Nguyen-Widrow adalah sebagai berikut[11]:

- a. Tentukan bilangan dengan jangkauan antara (-1.0) hingga 1.0.
- b. Hitung nilai bobot mutlak menggunakan persamaan 2.1.

$$\|V_{ij}\| = \sqrt{V_1^2 + V_2^2 + \dots + V_n^2} \quad (2.1)$$

- c. Hitung factor skala menggunakan persamaan 2.2.

$$\beta = 0.7 \sqrt[n]{p} = 0.7(p)^{1/n} \quad (2.2)$$

$\beta$  = faktor skala

n = jumlah *input neuron*

p = jumlah *hidden neuron*

- d. Mencari nilai  $V_{ij}$  menggunakan persamaan 2.3.

$$V_{ij} = \frac{\beta V_{ij}(\text{lama})}{\|V_{ij}\|} \quad (2.3)$$

i = input neuron ke-i

j = hidden neuron ke-j

$V_{ij}$  = bobot baru

$V_{ij}(\text{lama})$  = bobot lama

$\|V_{ij}\|$  = *bobot mutlak*

$\beta$  = faktor skala

- e. Tentukan bobot bias dengan menggunakan bilangan acak yang berada pada interval  $\beta$  dan  $-\beta$

### 3. Metodologi Penelitian

Berikut adalah tahapan – tahapan yang akan dilakukan dalam melakukan penelitian, diantaranya:

#### 3.1 Identifikasi Masalah

Pada tahap ini dilakukan identifikasi masalah terhadap masalah yang diangkat. Dalam hal ini penulis mengangkat masalah untuk memprediksi jumlah kasus demam berdarah dengue dengan algoritma Backpropagation, Particle Swarm Optimization, dan Nguyen Widrow.

#### 3.2 Studi Literatur

Pada tahap ini dilakukan studi literatur yang dapat menunjang dalam pengetahuan dan pengerjaan yang lebih baik terkait implementasi Backpropagation, Particle Swarm Optimization, dan Nguyen Widrow untuk memprediksi jumlah kasus demam berdarah. Studi literatur yang digunakan berasal dari berbagai sumber, seperti jurnal, e-book, dan internet yang berkaitan dengan topik penelitian yang diangkat.

#### 3.3 Pengumpulan Data

Data yang digunakan merupakan data sekunder yaitu data jumlah kasus demam berdarah per-bulan yang diambil dari situs Surveilans Dinas Kesehatan DKI Jakarta dan data iklim dari Badan Pusat Statistika DKI Jakarta yang keduanya tersedia online. Data iklim yang digunakan meliputi curah hujan, suhu udara maksimum, suhu minimum, suhu rata-rata, dan kelembaban udara maksimum, kelembaban minimum, dan kelembaban rata-rata. Periode data yang diambil yaitu data tahun 2012-2020. Data yang digunakan terdiri dari 108 record.

#### 3.4 Praproses Data

Pada tahap ini dilakukan normalisasi data sebelum diproses lebih lanjut. Teknik normalisasi data yang digunakan yaitu *Min-max Normalization*. Tujuan dari dilakukannya normalisasi data ini agar data berada pada rentang yang sama yaitu 0-1 sehingga keseluruhan data menjadiimbang.

#### 3.5 Pembagian Data

Pada tahap ini dilakukan pembagian data menjadi data latih dan data uji. Data yang dipakai untuk data latih merupakan data tahun 2012 hingga 2018 yang berjumlah 84 record dan untuk data uji digunakan data tahun 2019 dan 2020 yang terdiri dari 24 record.

#### 3.6 Modelling

##### 3.6.1 Pelatihan Backpropagation

Pada tahap ini dilakukan pelatihan dengan model Backpropagation dimana nilai bobot yang digunakan adalah bilangan random. Dalam membangun arsitektur jaringannya akan dilakukan percobaan variasi jumlah hidden neuron dan juga nilai learning rate untuk mencari hasil pemodelan dengan parameter terbaik. Percobaan variasi jumlah hidden neuron yang digunakan diantaranya 5,10,15,20,25, dan 30 serta percobaan learning rate yang digunakan yaitu 0.05, 0.1, 0.2, 0.3, dan 0.4. Selain itu, parameter tetap yang digunakan untuk pelatihan Backpropagation diantaranya 7 input neuron, 1 output neuron, epoch = 1000, dan fungsi aktivasi sigmoid biner.

### 3.6.2 Pelatihan PSO-Backpropagation

Selain dengan Backpropagation, tahapan ini juga dilakukan pelatihan dengan mengombinasikan algoritma Particle Swarm Optimization dengan Backpropagation. Penerapan PSO bertujuan untuk mengoptimalkan nilai bobot pada setiap lapisan pada jaringan Backpropagation untuk mendapatkan nilai error yang minimal. Pada pelatihan PSO-Backpropagation ini, dilakukan percobaan terlebih dahulu untuk mendapatkan parameter terbaik. Adapun parameter yang diujikan yaitu variasi hidden neuron diantaranya 5,10,15,20,25, dan 30 serta learning rate yaitu 0.05, 0.1, 0.2, 0.3, dan 0.4. Dari hasil hidden neuron dan learning rate kemudian digunakan untuk percobaan menguji jumlah partikel sebanyak 10 hingga 50 dan terakhir yaitu percobaan untuk menguji jumlah iterasi yaitu 10 hingga 50. Selain itu, parameter tetap yang digunakan untuk Backpropagation diantaranya 7 input neuron, 1 output neuron, epoch = 1000, dan fungsi aktivasi sigmoid biner serta parameter tetap untuk PSO yaitu  $w = 0.5$ ,  $c_1;c_2 = 0.8;0.9$ ,  $r_1;r_2 = 0.4;0.8$ .

### 3.6.3 Pelatihan Nguyen Widrow – Backpropagation

Pelatihan lainnya yang dilakukan yaitu pelatihan dengan Nguyen Widrow-Backpropagation. Dalam pelatihan ini dilakukan percobaan parameter untuk variasi hidden neuron dan learning rate. Variasi hidden neuron yang digunakan diantaranya 5,10,15,20,25, dan 30. Learning rate yang diujikan diantaranya 0.05, 0.1, 0.2, 0.3, dan 0.4. Selain itu, parameter tetap untuk pelatihan dengan Backpropagation diantaranya 7 input neuron, 1 output neuron, epoch = 1000, dan fungsi aktivasi sigmoid biner.

## 3.7 Pengujian

Selanjutnya yaitu tahapan pengujian. Pada tahap ini dilakukan pengujian menggunakan data testing yang berjumlah 24 record. Pengujian dilakukan berdasarkan model yang telah dilatih sebelumnya dengan metode Backpropagation, PSO-Backpropagation, dan Nguyen Widrow-Backpropagation. data dengan model yang sebelumnya telah dibangun. Pengujian dilakukan menggunakan Mean Squared Error (MSE) dengan perhitungan seperti pada persamaan 2.6 dan Mean Absolute Percentage Error (MAPE).

## 3.8 Analisa Hasil

Tahapan selanjutnya yaitu analisa hasil. Dari hasil pengujian yang telah dilakukan sebelumnya, dilakukan perbandingan hasil evaluasi diantara ketiga model. Perbandingan dilakukan dengan melihat nilai Mean Squared Error (MSE) dan Mean Absolute Percentage Error (MAPE) antara algoritma Backpropagation dengan PSO-Backpropagation, serta Nguyen widrow – Backpropagation. Semakin rendah nilai MSE dan MAPE maka dapat dikatakan bahwa algoritma tersebut bekerja lebih baik.

## 4. Hasil dan Pembahasan

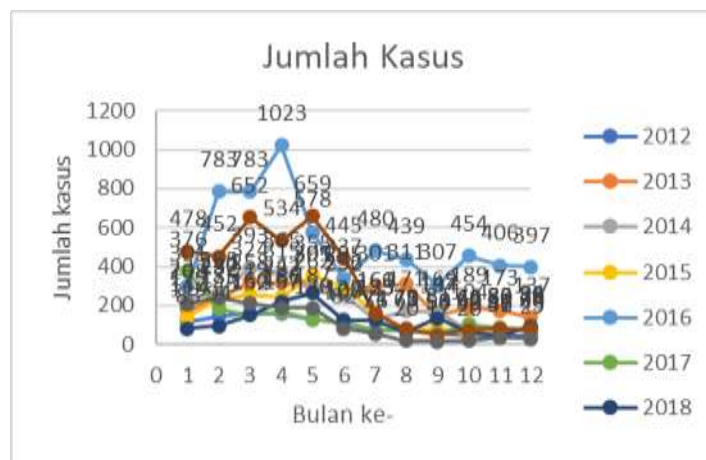
### 4.1 Pengumpulan Data

Data yang dikumpulkan dalam penelitian ini merupakan data Badan Pusat Statistika DKI Jakarta untuk data iklim dan data Surveilans Dinas Kesehatan DKI Jakarta untuk data jumlah kasus demam berdarah. Variabel data yang digunakan terdiri dari 7 variabel diantaranya yaitu curah hujan, suhu udara maksimum, suhu minimum, suhu rata-rata, kelembaban udara maksimum, kelembaban minimum, kelembaban rata-rata, dan jumlah kasus demam berdarah. Data yang digunakan disajikan pada Tabel 4.1 dan Gambar 4.1.

Tabel 4. 1 Data Iklim

Tahun	Bulan	Curah	Suhu	Kelembaban
-------	-------	-------	------	------------

		Hujan	Max	Min	Mean	Max	Min	Mean
2012	Januari	275.1	31.2	24.6	27.3	89	69	79
2012	Februari	157.9	157.9	25	27.9	88	72	80
2012	Maret	173.6	32.1	24.8	28	89	68	79
2012	April	196.2	32.4	25.3	28.1	87	72	80
2012	Mei	118	32.7	25.3	28.3	90	68	79
2012	Juni	67.2	32.7	25	28.4	86	67	76
2012	Juli	13.6	32.6	24.5	27.9	79	49	64
2012	Agustus	2.4	33.3	24.4	28.1	89	43	66
...	...	...	...	...	...	...	...	...
2020	Desember	236.5	34	24	28.13	97	56	79.3



Gambar 4. 1 Jumlah Kasus DBD

#### 4.2 Praproses Data

Berikut beberapa contoh dari perhitungan manual untuk normalisasi data dengan menggunakan data pada baris pertama di Tabel 4.1.

- a. Curah hujan, memiliki nilai maksimum 1075.0 dan minimum 0.0

$$\text{Curah hujan} = \frac{275.1 - 0.0}{1075.0 - 0.0} = 0.2559$$

- b. Suhu maksimum, memiliki nilai maksimum 157.9 dan minimum 21.1

$$\text{Suhu maksimum} = \frac{31.2 - 21.1}{157.9 - 21.1} = 0.07383$$

- c. Suhu minimum, memiliki nilai maksimum 37.8 dan minimum 22.4

$$\text{Suhu minimum} = \frac{24.6 - 22.4}{37.8 - 22.4} = 0.14285$$

Hasil keseluruhan normalisasi data yang telah dilakukan dideskripsikan pada Tabel 4.2.

Tabel 4. 2 Data Normalisasi

Curah Hujan	Suhu			Kelembaban			Jumlah Kasus
	Max	Min	Mean	Max	Min	Mean	

0.25591	0.07383	0.142857143	0.19391	0.56	0.60294	0.73913	0.10139
0.14688	1.0	0.168831169	0.36011	0.52	0.64706	0.78261	0.12724
0.16149	0.080409	0.155844156	0.38781	0.56	0.58824	0.73913	0.14215
0.18251	0.082602	0.188311688	0.41551	0.48	0.64706	0.78261	0.13917
0.10977	0.084795	0.188311688	0.47091	0.6	0.58824	0.73913	0.11233
0.06251	0.084795	0.168831169	0.49861	0.44	0.57353	0.6087	0.09046
0.01265	0.084064	0.136363636	0.36011	0.16	0.30882	0.08696	0.05368
0.00223	0.089181	0.12987013	0.41551	0.56	0.22059	0.17391	0.06163
...	...	...	...	...	...	...	...
0.22	0.094298	0.103896	0.423823	0.88	0.411765	0.752174	0.01192

### 4.3 Pembagian Data

Dalam tahapan ini dilakukan pembagian data latih dan data uji. Data latih yang digunakan yaitu data pada tahun 2012-2018, sedangkan data uji yang digunakan yaitu data tahun 2019 dan 2020. Keseluruhan data terdiri dari 108 record dimana data latih sebanyak 84 record dan data uji sebanyak 24 record. Setelah dilakukan pembagian data antara data uji dan data latih, dilakukan pemisahan antara fitur dan target. Fitur yang digunakan yaitu variabel data iklim yang terdiri dari 7 fitur diantaranya curah hujan, suhu udara maksimum, suhu minimum, suhu rata-rata, kelembaban udara maksimum, kelembaban minimum dan kelembaban rata-rata. Sedangkan, target yang digunakan yaitu data jumlah kasus demam berdarah.

### 4.4 Training Data

#### 4.4.1 Perancangan Model Backpropagation

Dalam penelitian ini, perancangan model backpropagation dilakukan dengan melakukan percobaan variasi jumlah hidden neuron dan nilai learning rate. Jumlah hidden neuron yang digunakan yaitu 5-30 hidden neuron dengan kelipatan 5.

Selain itu, arsitektur jaringan saraf tiruan yang digunakan terdiri dari 7 input layer, variasi hidden layer, dan 1 output layer. Tujuan dari dilakukannya percobaan variasi hidden neuron dan learning rate untuk mencari parameter yang memiliki hasil pelatihan paling optimal. Dari percobaan yang telah dilakukan hasil pelatihan terbaik diringkas dalam Tabel 4.3.

Tabel 4. 3 Hasil terbaik tiap learning rate

Model	Hidden Neuron	Learning rate	MSE Training	Time (s)
Backpropagation	10	0.05	$2,067 \times 10^{-2}$	10,2
	5	0.1	$2,024 \times 10^{-2}$	9,7
	5	0.2	$2,056 \times 10^{-2}$	8,8
	5	0.3	$2,081 \times 10^{-2}$	9,8
	10	0.4	$2,315 \times 10^{-2}$	7,2

Berdasarkan Tabel 4.3 terlihat bahwa nilai MSE atau *error* terbaik berada pada parameter dengan jumlah *hidden neuron* sebanyak 5 dan *learning rate* 0.1 yaitu sebesar  $2,024 \times 10^{-2}$  dengan waktu pelatihan sebesar 9.7 detik.

#### 4.4.2 Perancangan Model PSO-Backpropagation

Dalam penelitian ini, penggunaan metode PSO bertujuan untuk mencari nilai bobot paling optimal dimana

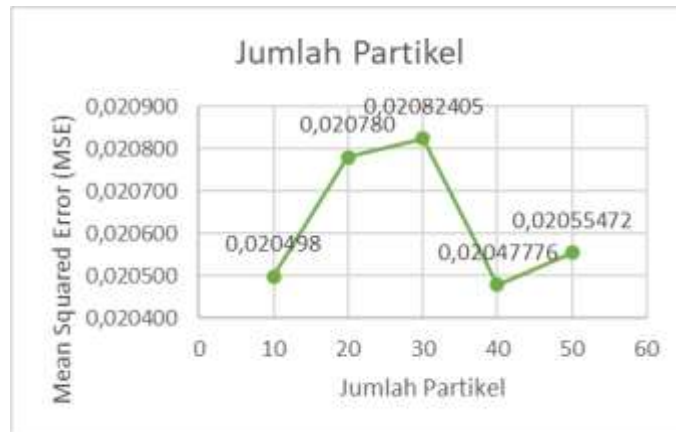


bobot yang memiliki nilai error terkecil. Nilai bobot tersebut digunakan sebagai bobot untuk pelatihan Backpropagation. Kondisi berhenti yang digunakan untuk pelatihan Backpropagation yaitu nilai epoch. Parameter neural network yang digunakan dalam implementasi program PSO-Backpropagation sama seperti perancangan pada model backpropagation, dimana terdiri dari 7 input neuron, variasi hidden neuron yaitu dalam rentang 5-30, dan 1 output neuron. Pada percobaan yang dilakukan, nilai *hidden neuron* yang diuji yaitu 5,10,15,20,25, dan 30. Untuk nilai *learning rate* yaitu 0.05, 0.1, 0.2, 0.3, dan 0.4. Parameter lain yang digunakan untuk menguji *hidden neuron* dan *learning rate* yaitu  $w = 0.5$ ,  $c_1;c_2 = 0.8;0.9$ ,  $r_1;r_2 = 0.4;0.8$ , jumlah partikel = 10, dan jumlah iterasi = 10. Hasil yang didapatkan dari percobaan yang dilakukan ditunjukkan pada Tabel 4.4.


Tabel 4. 4 Hasil uji hidden neuron dan learning rate

Model	Hidden Neuron	Learning rate	MSE Training	Time (s)
PSO - Backpropagation	20	0.05	$2,097 \times 10^{-2}$	16,3
	10	0.1	$2,050 \times 10^{-2}$	16,7
	5	0.2	$2,080 \times 10^{-2}$	17,0
	10	0.3	$2,122 \times 10^{-2}$	15,1
	5	0.4	$6,807 \times 10^{-2}$	16,1

Percobaan lainnya yang dilakukan yaitu jumlah partikel yang diuji diantaranya yaitu 10 hingga 50. Jumlah *hidden neuron* dan *learning rate* yang digunakan disesuaikan dengan nilai terbaik yang didapatkan dari uji parameter *hidden neuron* dan *learning rate* yaitu 10 dan 0.1. Parameter lain yang digunakan yaitu  $w = 0.5$ ,  $c_1;c_2 = 0.8;0.9$ ,  $r_1;r_2 = 0.4;0.8$ , dan jumlah iterasi = 10. Hasil uji parameter untuk jumlah partikel ditunjukkan pada Gambar 4.2. Setelah itu percobaan dilanjutkan untuk jumlah iterasi yang hasilnya diilustrasikan pada Gambar 4.3.



Gambar 4. 2 Hasil uji jumlah partikel



Gambar 4. 3 Hasil uji jumlah iterasi

Berdasarkan dari keseluruhan pengujian parameter yang dilakukan untuk PSO-Backpropagation didapatkan parameter yang akan digunakan untuk proses pengujian yaitu  $w = 0.5$ ,  $c_1; c_2 = 0.8; 0.9$ ,  $r_1; r_2 = 0.4; 0.8$ , jumlah partikel = 40, hidden neuron = 10, dan learning rate 0.1, serta jumlah iterasi sebanyak 30.

#### 4.4.3 Perancangan Model NW-Backpropagation

Dalam penelitian ini, dilakukan percobaan untuk parameter dengan variasi hidden neuron dan variasi learning rate diantaranya 0.05, 0.1, 0.2, 0.3, dan 0.4. Parameter lainnya yang digunakan sama seperti model backpropagation saja yaitu epoch = 1000, dan fungsi aktivasi sigmoid biner. Berdasarkan keseluruhan percobaan yang dilakukan untuk model Nguyen Widrow – Backpropagation, berikut ringkasan hasil disajikan pada Tabel 4.5.

Tabel 4. 5 Hasil terbaik tiap learning rate

Model	Hidden Neuron	Learning rate	MSE Training	Time (s)

NW - Backpropagation	10	0.05	$2,006 \times 10^{-2}$	7,0
	5	0.1	$1,972 \times 10^{-2}$	6,8
	20	0.2	$2,125 \times 10^{-2}$	7,0
	5	0.3	$2,049 \times 10^{-2}$	6,5
	5	0.4	$2,984 \times 10^{-2}$	6,7

Berdasarkan hasil training yang disajikan pada tabel, terlihat bahwa hasil terbaik didapatkan pada hidden neuron sebanyak 5 dengan nilai MSE yaitu  $1,972 \times 10^{-2}$  dan waktu pelatihan selama 6.8 detik serta *learning rate* = 0.1.

#### 4.5 Pengujian Data

Dalam tahapan testing data, parameter yang digunakan merupakan hasil dari proses training dengan tiga model yang telah dilakukan sebelumnya. Data yang digunakan dalam proses testing merupakan data tahun 2019 dan 2020 dari bulan Januari hingga bulan Desember. Data testing yang digunakan juga telah dilakukan preprocessing terlebih dahulu dan kemudian diterapkan dengan model yang telah dilatih.

Parameter yang digunakan untuk pengujian model backpropagation yaitu jumlah hidden neuron = 5, learning rate = 0.1, epoch = 1000, dan fungsi aktivasi sigmoid biner. Hasil Mean Squared Error (MSE) testing yang didapatkan yaitu sebesar  $4,76 \times 10^{-2}$ .

Selain itu, parameter yang digunakan untuk pengujian model PSO-Backpropagation diantaranya yaitu  $w = 0.5$ ,  $c_1; c_2 = 0.8; 0.9$ ,  $r_1; r_2 = 0.4; 0.8$ , jumlah partikel = 40, hidden neuron = 10, dan learning rate 0.1, serta jumlah iterasi sebanyak 30. Hasil Mean Squared Error yang didapatkan yaitu sebesar  $4,44 \times 10^{-2}$ .

Pengujian terakhir untuk model Nguyen Widrow – Backpropagation, parameter yang digunakan antara lain hidden neuron = 5, learning rate = 0.1, epoch = 1000, dan fungsi aktivasi sigmoid biner. Hasil Mean Squared Error (MSE) testing yang didapatkan yaitu sebesar  $5,70 \times 10^{-2}$ .

Selain menggunakan Mean Squared Error, pengujian data dilakukan juga dengan menggunakan Mean Absolut Percentage error (MAPE). Hasil nilai MAPE yang didapatkan dari pengujian model Backpropagation, PSO-Backpropagation, dan Nguyen Widrow-Backpropagation berturut-turut adalah 19.05%, 18.43%, dan 20.72%. Hasil keseluruhan pengujian data dideskripsikan pada Tabel 4.6


Tabel 4.6 Hasil Pengujian Data

Model	MSE	MAPE	Hasil Prediksi
Backpropagation	$4,76 \times 10^{-2}$	19.05%	Baik
PSO - Backpropagation	$4,44 \times 10^{-2}$	18.43%	Baik
NW - Backpropagation	$5,70 \times 10^{-2}$	20.72%	Layak

#### 4.6 Analisa Hasil


Hasil dari percobaan yang telah dilakukan dengan model *Backpropagation*, *PSO-Backpropagation*, dan *Nguyen Widrow-Backpropagation* dapat dilihat dengan menggunakan MSE (Mean Squared Error) dan

MAPE (Mean Absolute Percentage Error). Berikut adalah percobaan yang dilakukan mulai dari pelatihan dan pengujian dideskripsikan pada Gambar 4.4, 4.5, dan 4.6.



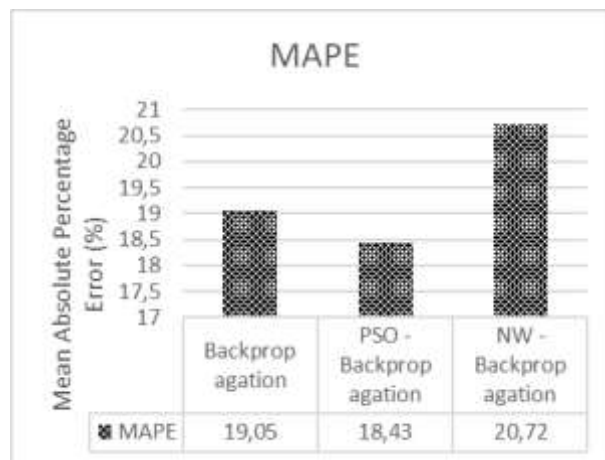
Gambar 4. 4 Hasil MSE pelatihan

Pada pelatihan dan pengujian model yang telah dibangun, selanjutnya dapat dilakukan analisa hasil yang didapatkan. Pada pelatihan model Backpropagation, hasil MSE terbaik yang didapatkan yaitu sebesar  $2,02 \times 10^{-2}$  dengan waktu pelatihan selama 9.7 detik. Hasil tersebut didapatkan setelah dilakukan pengujian parameter terhadap jumlah hidden neuron dan nilai learning rate. Adapun parameter yang menghasilkan nilai terbaik untuk model backpropagation yaitu parameter dengan jumlah hidden neuron = 5 dan learning rate sebesar 0.1. Selanjutnya, pada pelatihan PSO-Backpropagation, hasil MSE terbaik yang didapatkan yaitu sebesar  $2,03 \times 10^{-2}$  dan waktu pelatihan selama 13.4 detik. Adapun parameter terbaik yang digunakan setelah dilakukan beberapa uji parameter yaitu dengan jumlah hidden neuron sebanyak 10, learning rate 0.1, jumlah partikel sebanyak 40 dan jumlah iterasi yaitu 30. Pelatihan model terakhir yaitu Nguyen Widrow – Backpropagation, hasil MSE terbaik yaitu sebesar  $1,972 \times 10^{-2}$  dan waktu pelatihan selama 6.8 detik, serta parameter yang digunakan yaitu hidden neuron sebanyak 5 dan learning rate 0.1. Dari hasil pelatihan yang didapatkan oleh ketiga model, hasil terbaik dengan nilai MSE terendah yaitu pelatihan dengan model Nguyen Widrow – Backpropagation, dilanjutkan dengan model backpropagation dan terakhir PSO-Backpropagation. Hasil MSE pelatihan tiap model diilustrasikan pada Gambar 4.4.



Gambar 4.5 Hasil MSE pengujian

Selanjutnya, pada pengujian data didapatkan hasil MSE untuk model Backpropagation, PSO-Backpropagation, dan Nguyen Widrow – Backpropagation secara berturut-turut adalah  $4,76 \times 10^{-2}$ ,  $4,44 \times 10^{-2}$ , dan  $5,70 \times 10^{-2}$ . Hasil tersebut menunjukkan bahwa model PSO-Backpropagation lebih baik dibandingkan dengan kedua model lainnya. Model Nguyen Widrow – Backpropagation yang memiliki hasil terbaik diantara kedua model lainnya pada pelatihan namun menjadi yang paling besar nilai error yang didupatkannya. Berikut hasil MSE pengujian diilustrasikan pada Gambar 4.16.



Gambar 4. 6 Hasil MAPE pengujian

Berdasarkan hasil pengujian dengan nilai MAPE yang diilustrasikan pada Gambar 4.17 didapatkan bahwa hasil pemodelan terbaik yaitu menggunakan model PSO-Backpropagation dimana nilai MAPE yang didapatkan yaitu sebesar 18,43% diikuti dengan model *backpropagation* dengan MAPE 19.05%, dan Nguyen Widrow 20.72%. Hasil dari model *PSO-Backpropagation* dan *Backpropagation* berada pada interval 10% - 20% sehingga dapat dikatakan bahwa kemampuan prediksi kedua model bekerja dengan baik. Selain itu, untuk pemodelan Nguyen Widrow dapat dikatakan layak untuk melakukan prediksi.

## 5. Penutup

### 5.1 Kesimpulan

Berdasarkan penelitian yang telah dilakukan dapat ditarik beberapa kesimpulan diantaranya sebagai berikut:

- a. Dari pengujian parameter untuk hidden neuron 5, 10, 15, 20, 25 dan 30 serta learning rate 0.05, 0.1, 0.2, 0.3, dan 0.4 dengan maksimum nilai epoch sebesar 1000 dan menggunakan fungsi aktivasi sigmoid biner didapatkan bahwa parameter terbaik model Backpropagation dan Nguyen Widrow-Backpropagation yaitu dengan jumlah hidden neuron = 5 dan learning rate 0.1.
- b. Dari pengujian untuk parameter PSO-Backpropagation untuk hidden neuron 5,10,15,20,25, dan 30, learning rate 0.05, 0.1, 0.2, 0.3, dan 0.4, jumlah partikel dan jumlah iterasi 10 hingga 50 dengan maksimum nilai epoch sebesar 1000 dan menggunakan fungsi aktivasi sigmoid biner didapatkan bahwa parameter terbaik model PSO-Backpropagation yaitu dengan jumlah hidden neuron = 10, learning rate 0.1, jumlah partikel = 40, dan jumlah iterasi = 30.
- c. Hasil MSE pelatihan terbaik yaitu menggunakan model Nguyen Widrow – Backpropagation dengan nilai sebesar  $1,972 \times 10^{-2}$ . Kemudian dilanjutkan dengan hasil MSE pelatihan Backpropagation dan PSO-Backpropagation yaitu  $2,02 \times 10^{-2}$  dan  $2,03 \times 10^{-2}$ .
- d. Hasil pengujian yang didapatkan untuk nilai MSE dan MAPE model Backpropagation, PSO-Backpropagation, dan Nguyen Widrow-Backpropagation secara berturut-turut adalah  $4,76 \times 10^{-2}$  dan 19.05%,  $4,44 \times 10^{-2}$  dan 18.43%,  $5,70 \times 10^{-2}$  dan 20.72%.
- b. Hasil pemodelan terbaik didapatkan oleh PSO-Backpropagation dengan nilai MSE sebesar  $4,44 \times 10^{-2}$  dan MAPE sebesar 18.43%

### 5.2 Saran

Adapun beberapa saran dari kami untuk penelitian di masa yang akan datang, diantaranya sebagai berikut:

- a. Penerapan model Backpropagation, PSO-Backpropagation, dan Nguyen Widrow – Backpropagation untuk permasalahan lain.
- b. Penerapan algoritma lainnya untuk memprediksi jumlah kasus demam berdarah.
- c. Penggunaan data yang lebih besar dan variabel lainnya.
- d. Pengujian parameter lainnya seperti nilai  $c1$ ,  $c2$ ,  $w$ ,  $r1$ , ataupun  $r2$  untuk model PSO.

## Referensi

- [1] RI, K. K. (2017). Pedoman Pencegahan dan Pengendalian Demam Berdarah Dengue di Indonesia. Jakarta: Direktorat Jenderal Pengendalian Penyakit dan Penyehatan Lingkungan.
- [2] Hii, Y. L., Zhu, H., Ng, N., Ng, L. C., & Rocklöv, J. (2012). Forecast of Dengue Incidence Using Temperature and Rainfall. *Plos Neglected Tropical Diseases*.
- [3] WHO. (2021, Mei 19). Dengue and severe dengue. Retrieved from World Health Organization: <https://www.who.int/news-room/fact-sheets/detail/dengue-and-severe-dengue>

- [4] Kementerian Kesehatan RI. (2016). InfoDATIN Situasi DBD di Indonesia. Pusat Data dan Informasi Kementerian Kesehatan RI.
- [5] CNN. (2019, Januari). Situasi Demam Berdarah di Indonesia Naik Turun. Retrieved from CNN Indonesia: <https://www.cnnindonesia.com/gaya-hidup/20190122103351-255-362707/situasi-demam-berdarah-di-indonesia-naik-turun>.
- [6] Solikhun, S., & Wahyudi, M. (2020). JARINGAN SARAF TIRUAN Backpropagation Pengenalan Pola Calon Debitur. Yayasan Kita Menulis.
- [7] Yessa, A. R., & Hardjianto, M. (2020). Prediction of Water Use Using BACKpropagation Neural Network Method and Particle Swarm Optimization. bit-Tech.
- [8] Wanto, A., Windarto, A. P., Nasution, D., Tambunan, F., Hasibuan, M. S., Siregar, M. N., . . . Nofriansyah, D. (2020). Jaringan Saraf Tiruan: Algoritma Prediksi dan Implementasi. Yayasan Kita Menulis.
- [9] Zaied, B. K., Rashid, M., Nasrullah, M., Bari, B. S., Zularisam, A. W., & Singh, L. (2020). Prediction and optimization of biogas production from POME co-digestion in solar bioreactor using artificial neural network coupled with particle swarm optimization (ANN-PSO). Biomass Conversion and Biorefinery.
- [10] Santosa, B., & Willy, P. (2011). Metoda metaheuristik, Konsep dan Implementasi. Graha Ilmu.
- [11] Mahfuzh, H. F. (2020). PENGARUH ALGORITMA INISIALISASI NGUYEN WIDROW TERHADAP BACKPROPAGATION DALAM PREDIKSI INDEKS HARGA KONSUMEN (IHK). SENAMIKA, 711.