



Prediksi Distribusi Air Perusahaan Daerah Air Minum (PDAM) Tirta Dharma Kota Pasuruan Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation

Dwi Agustina¹, Moh. Hafiyusholeh², Aris Fanani³, Dono Prasetijo⁴

^{1,2,3} Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sunan Ampel, Gunung Anyar, Surabaya, Jawa Timur 60294, Indonesia.

⁴ Perusahaan Daerah Air Minum (PDAM) Kota Pasuruan, Jl. Erlangga No.4, Purworejo, Pasuruan, Jawa Timur 67115, Indonesia.

ABSTRACT

The most important resource for daily needs is clean water, which every human being has the right to use. The author uses a backpropagation neural network to assist PDAM Tirta Dharma, Pasuruan City in determining the estimated distribution of water to customers for the coming period. Water distribution data obtained directly from PDAM Pasuruan City between January 2019 to December 2021 was used in this study. In this study the architectures used are 4-2-1, 4-4-1, and 4-8-1, with 4-2-1 being the best because it has an accuracy rate of 100%, learning rate 0.1, target error 0.001, and a maximum epoch of 1000. The predicted number of PDAM Tirta Dharma Pasuruan city water distribution in 2022 was 6,829,056, in 2023 there were 6,865,358, in 2024 there were 6,867,817, and in 2025 there were 6,868,785.

Keywords: backpropagation, water distribution, artificial neural network, PDAM Pasuruan, prediction

ABSTRAK

Setiap Sumber daya yang paling penting untuk kebutuhan sehari-hari adalah air bersih, yang berhak digunakan oleh setiap manusia. Penulis menggunakan jaringan syaraf tiruan *backpropagation* guna membantu PDAM Tirta Dharma Kota Pasuruan dalam menentukan perkiraan distribusi air ke pelanggan untuk periode yang akan datang. Data distribusi air yang diperoleh langsung dari PDAM Kota Pasuruan antara Januari 2019 hingga Desember 2021 digunakan dalam penelitian ini. Dalam penelitian ini arsitektur yang digunakan adalah 4-2-1, 4-4-1, dan 4-8-1, dengan 4-2-1 menjadi yang terbaik karena memiliki tingkat akurasi 100%, learning rate 0.1, target error 0.001, dan maximum epoch 1000. Jumlah prediksi distribusi air PDAM Tirta Dharma Kota Pasuruan tahun 2022 diperoleh sebanyak 6.829.056, tahun 2023 sebanyak 6.865.358, tahun 2024 sebanyak 6.867.817, dan tahun 2025 sebanyak 6.868.785.

Kata Kunci: backpropagation, distribusi air, jaringan syaraf tiruan, PDAM Pasuruan, prediksi

1. PENDAHULUAN

Air merupakan sumber daya alam dengan fungsi penting yang tidak terlepas dari kehidupan manusia, hewan, dan tumbuhan. Air merupakan sumber kebutuhan manusia untuk kelangsungan hidup. Air memiliki manfaat untuk layanan fasilitas serta kebutuhan keluarga. Seiring dengan percepatan pertumbuhan penduduk, kemajuan pembangunan dan peningkatan taraf hidup, demikian pula kebutuhan air bersih terus meningkat. Maka dari itu, masyarakat harus konsisten dalam kualitas pengelolaan perusahaan dan pelayanan air bersih.

Di kota Pasuruan, pemerintah kolonial Belanda pertama kali mengelola persediaan air pada tahun 1915 dan menamainya "InlodoWater Bedrijf", yang berasal dari lokasi mata air di desa Kedung Waru dan Umbulan di kecamatan Winongan kabupaten Pasuruan. Pasca kemerdekaan, Perusahaan Saluran Air Minum (SAM) mengelola penyediaan air untuk Kota Pasuruan. Namun pada tahun 1982, Perda Pasuruan Daerah Tingkat II Nomer 2 Tahun 1982 menetapkan bahwa Perusahaan SAM berubah nama menjadi PDAM Tirta Dharma kota Pasuruan. Sejarah berdirinya PDAM Tirta Dharma di Kota Pasuruan juga memuat perda ini.[1].

Perusahaan Daerah Air Minum (PDAM) Tirta Dharma kota Pasuruan bertugas mengelola penyediaan air untuk meningkatkan kesejahteraan manusia, meliputi aspek sosial, kesejahteraan dan pelayanan publik yang dikelola secara profesional berdasarkan prinsip bisnis [2]. Namun, salah satu kendala pemenuhan kebutuhan air PDAM adalah jumlah air yang diproduksi lebih besar dari jumlah yang didistribusikan, yang menunjukkan adanya kehilangan air. Di sisi lain, ketika jumlah air yang diproduksi lebih sedikit dari jumlah yang didistribusikan, maka terjadi kekurangan air di pihak pelanggan. Dalam hal ini diperlukan sebuah prediksi untuk menentukan jumlah air yang didistribusikan kepada pelanggan.

Adaptive Neuro Fuzzy Inference System (ANFIS) [3], box-jenkins[4], dan Jaringan Syaraf Tiruan (JST) adalah beberapa teknik yang dapat digunakan untuk memprediksi distribusi air [5]. Pada penelitian dilakukan prediksi distribusi air dengan metode JST. Konsep dari JST adalah mengolah data distribusi air dari tahun 2019 hingga 2021 untuk memprediksi distribusi air PDAM, yang dimasukkan ke dalam sistem melalui proses pelatihan menggunakan metode JST dengan algoritma *backpropagation*. Sistem membuat bobot yang digunakan untuk memperkirakan distribusi air PDAM di masa mendatang setelah tahap pelatihan.

Jaringan syaraf tiruan bekerja dengan baik dalam teknologi pengenalan pola (*pattern recognition*) [6]. Analisis data, pengenalan pola, dan fungsi kontrol adalah tiga bidang dasar paling umum dari jaringan syaraf tiruan dalam beberapa tahun terakhir. Keunggulan jaringan syaraf tiruan (JST) untuk belajar dari lingkungannya. Sampai keadaan yang diinginkan tercapai, proses adopsi otak manusia melibatkan pembelajaran melalui pengamatan dan pengulangan. Jaringan syaraf tiruan dapat diimplementasikan dalam berbagai cara. Dalam penelitian ini menggunakan algoritma *backpropagation*.

Dalam *supervised learning*, *backpropagation* adalah metode pembelajaran yang paling umum digunakan. Masalah pengenalan pola yang kompleks dapat diselesaikan dengan menggunakan metode ini [7]. Metode ini dapat digunakan untuk menentukan gradien yang mengurangi kesalahan kuadrat keluaran. Tiga tahapan pelatihan jaringan adalah propagasi maju, propagasi balik, dan perubahan bobot dan bias [8]. Lapisan masukan menerima data, lapisan tersembunyi memprosesnya, dan lapisan keluaran menghasilkan keluaran berdasarkan masukan dalam tipikal topologi jaringan saraf *backpropagation*.

Berdasarkan penelitian sebelumnya Anjar Wanto (2019) memprediksi produktivitas jagung Indonesia tahun 2019-2020 menggunakan Jaringan Saraf Tiruan *Backpropagation* dengan akurasi 88%. Selanjutnya penelitian Irawan (2015) memprediksi kebutuhan air PDAM kota Malang menggunakan metode JST *backpropagation* dengan menggunakan variabel distribusi air PDAM dan data pemakaian air bulan berikutnya untuk setiap kecamatan di kota Malang. Hasil pengujian mencapai akurasi tertinggi 95,17%. Penelitian lain yang dilakukan oleh Vamsidhar (2010) menggunakan metode JST *backpropagation* untuk memprediksi curah hujan dengan akurasi 94,28%.

Pramonoaji (2013) memprediksi distribusi air PDAM kota Semarang berdasarkan populasi, total volume produksi, jenis pelanggan, kontribusi wilayah, air terjual, kehilangan air dan total volume produksi dengan tingkat akurasi 95,56%, MSE 0.074416, dan MAE 0.102487. Sedangkan penelitian Nikmah (2014) menggunakan algoritma AI-Alaoui *Backpropagation* untuk memprediksi kebutuhan air PDAM berdasarkan jumlah pelanggan dengan tingkat akurasi 92%.

Berdasarkan kelebihan JST *backpropagation* yang telah dijelaskan di atas, penulis mengkaji lebih lanjut dengan penerapan metode prediksi dan membahasnya dengan judul "Prediksi Distribusi Air Minum Perusahaan Daerah Air Minum (PDAM) Tirta Dharma Kota Pasuruan Menggunakan Metode Jaringan Syaraf Tiruan *Backpropagation*". Dengan harapan dapat tercapainya tujuan penelitian yaitu mengetahui berapa banyak air yang didistribusikan ke pelanggan.

2. TINJAUAN PUSTAKA

2.1. Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) adalah metode dalam kecerdasan buatan. Kemampuannya yaitu pengenalan pola, pemrosesan sinyal dan prediksi [10]. Lapisan penyusun JST terbagi menjadi tiga antara lain [11]:

1. Unit input merupakan unit di dalam lapisan input. Unit input ini menerima pola data masukan dari luar yang menjelaskan permasalahan.
2. Unit tersembunyi merupakan unit pada lapisan tersembunyi.
3. Unit output merupakan unit pada lapisan output.

2.2. Algoritma *Backpropagation*

Backpropagation adalah metode yang menangani masalah prediksi, identifikasi, dan pengenalan pola [12]. *Backpropagation*, sejenis JST yang digunakan untuk memecahkan masalah prediksi. Ini mungkin adalah jenis pelatihan JST yang diatur. Jaringan menerima sepasang pola yang diinginkan dan pola masukan. Bobot diubah ketika pola diberikan ke jaringan untuk mengurangi kesenjangan antara pola keluaran dan pola yang diinginkan. Untuk memastikan setiap pola jaringan yang dihasilkan sesuai dengan pola yang diinginkan, latihan ini diulangi [13].

Masalah kompleks sering diselesaikan dengan algoritma *backpropagation*, karena metode pembelajaran digunakan untuk melatih algoritma ini. Pelatihan *backpropagation* dapat dilakukan dengan menggunakan metode ini dalam tiga fase yaitu *feed forward*, *backpropagation*, dan fase perubahan bobot. Sampai kondisi perhentian terpenuhi, ketiga fase ini terus dilakukan [14].

2.3. Normalisasi Data

Menormalisasikan data terlebih dahulu sebelum diproses. Data dinormalisasi menggunakan output jaringan berdasarkan fungsi aktivasi sigmoid (biner) yaitu fungsi asimtotik yang tidak pernah mencapai 0 atau 1 [15]. Ini menyebabkan normalisasi data terjadi pada interval yang lebih kecil, yaitu 0.1-0.9. Persamaan 1 dan 2 dapat digunakan untuk normalisasi dan denormalisasi.

$$x' = \frac{x-a}{b-a} (0,8) + 0,1 \quad (1)$$

$$x'' = \frac{x'-(0,1)}{0,8} (b-a) + a \quad (2)$$

dimana :

a = data minimum

b = data maksimum

- x' = data yang telah ditransformasi
- x = data yang akan dinormalisasi
- x'' = data yang akan didenormalisasi

2.4. Langkah-Langkah Algoritma Backpropagation

Tahap pelatihan *backpropagation* terdiri dari tahap maju, tahap mundur, dan tahap modifikasi bobot untuk menurunkan tingkat kesalahan [16]. Berikut adalah penjelasan mengenai langkah-langkah dalam algoritma *backpropagation* :

1. Gunakan bilangan acak kecil untuk mengatur semua bobot.
2. Jika kondisi yang diinginkan tidak terpenuhi, lakukan langkah3-4.
3. Lakukan langkah 4-8 untuk setiap pasangan data *training* yang digunakan.
Fase I : Tahap maju (*feedforward*)
4. Menghitung hasil pada unit tersembunyi z_j , ($j = 1, 2, \dots, p$) ditunjukkan pada persamaan 3 dan 4.

$$z_{net_j} = v_{j0} + \sum_{i=1}^n x_i v_{ji} \quad (3)$$

Menghitung aktifasi dengan fungsi sigmoid biner :

$$z_j = f(z_{net_j}) = \frac{1}{1 + \exp(-z_{net_j})} \quad (4)$$

dimana :

- v_{j0} = bobot bias lapisan input ke lapisan tersembunyi ($j = 1, 2, \dots, p$)
 - x_i = unit masukkan ke- i , ($i = 1, 2, 3, \dots, n$)
 - v_{ji} = bobot unit masukkan dari lapisan input ke lapisan tersembunyi
 - z_j = unit keluaran di lapisan tersembunyi
 - $f(z_{net_j})$ = fungsi aktivasi
- Semua unit lapisan tersembunyi menerima keluaran fungsi aktifasi.

5. Menghitung hasil pada unit output y_k untuk ($k = 1, 2, \dots, m$) dengan menggunakan persamaan 5 dan 6.

$$y_{net_k} = w_{k0} + \sum_{j=1}^p z_j w_{kj} \quad (5)$$

$$y_k = f(y_{net_k}) = \frac{1}{1 + \exp(-y_{net_k})} \quad (6)$$

dimana :

- w_{k0} = bobot bias lapisan tersembunyi ke lapisan output
 - z_j = unit keluaran ke- j di lapisan tersembunyi ($j = 1, 2, \dots, p$)
 - w_{kj} = bobot unit masukan dari lapisan output ke lapisan tersembunyi
 - y_k = unit keluaran di lapisan tersembunyi
 - $f(y_{net_k})$ = fungsi aktivasi
- Fase II : Tahap Mundur (*backpropagation*)

6. Menghitung nilai faktor δ pada unit keluaran dari nilai *error* pada setiap unit keluaran y_k untuk ($k = 1, 2, \dots, m$) dengan menggunakan persamaan 7.

$$\begin{aligned} \delta_k &= (t_k - y_k) f'(y_{net_k}) \\ &= (t_k - y_k) y_k (1 - y_k) \end{aligned} \quad (7)$$

dimana :

- δ_k = unit kesalahan ke- k
 - t_k = *target* ke- k
 - y_k = unit keluaran ke- k
- δ_k digunakan untuk mengubah bobot layer bawahnya.

Dengan menggunakan persamaan 8, hitung laju perubahan bobot w_{kj} yang digunakan untuk mengubah bobot w_{kj} dengan laju pembelajaran α .

$$\Delta w_{kj} = \alpha \delta_k z_j; k = 1, 2, \dots, m; j = 0, 1, \dots, p \quad (8)$$

dimana :

- Δw_{kj} = suku perubahan bobot w_{kj}
- α = laju pembelajaran
- δ_k = unit kesalahan ke- k
- z_j = unit keluaran ke- j di lapisan tersembunyi ($j = 0, 1, \dots, p$)

7. Menghitung nilai faktor δ pada unit tersembunyi dari nilai *error* pada unit tersembunyi z_j , ($j = 0, 1, \dots, p$) dengan menggunakan persamaan 9.

$$\delta_{net_j} = \sum_{k=1}^m \delta_k w_{kj} \quad (9)$$

Persamaan 10 dapat digunakan untuk menentukan faktor δ untuk unit tersembunyi.

$$\begin{aligned} \delta_j &= \delta_{net_j} f' z_{net_j} \\ &= \delta_{net_j} z_j (1 - z_k) \end{aligned} \quad (10)$$

Dengan menggunakan persamaan 11, laju perubahan bobot v_{kj} yang digunakan untuk mengubah bobot v_{ij} dengan laju pembelajaran α dapat dihitung.

$$\Delta v_{ji} = \alpha \delta_j x_i; j = 1, 2, \dots, p; i = 0, 1, \dots, n \quad (11)$$

Fase III : Perubahan bobot

8. Perubahan bobot terhadap unit output dapat dihitung menggunakan persamaan 12.

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj} (k = 1, 2, \dots, m; j = 0, 1, \dots, p) \quad (12)$$

Perubahan bobot bias terhadap unit output dapat dilihat pada persamaan 13.

$$v_{ji}(\text{baru}) = v_{ji}(\text{lama}) + \Delta v_{ji} (j = 1, 2, \dots, p; i = 0, 1, \dots, n) \quad (13)$$

Tahap pengujian jaringan dimulai setelah tahap pelatihan selesai. Langkah pada tahap ini hanya sampai fase I. Semua bobot yang dimasukkan berasal dari nilai bobot tahap akhir pelatihan. Berdasarkan data baru yang diberikan, diharapkan jaringan dapat mengenali pola selama tahap pengujian [17].

2.5. Mean Squared Error

Rata-rata kesalahan prediksi yang dikuadratkan dapat digunakan untuk menghitung nilai error menggunakan metode *Mean Squared Error* (MSE). Perhitungan MSE menggunakan rumus persamaan 14.

$$MSE = \frac{1}{n} \sum_{t=1}^n A_t - F_t^2 \quad (14)$$

dimana :

n = jumlah data

A_t = nilai awal data ke- t

F_t = nilai ramalan data ke- t

2.6. Perhitungan Akurasi

Memanfaatkan data uji untuk menghitung akurasi pada langkah propagasi maju. Menggunakan persamaan 15 untuk menghitung akurasi:

$$\text{Akurasi} = 100\% - \text{MAPE} \quad (15)$$

3. METODOLOGI PENELITIAN

Penelitian ini menggunakan survey atau metode deskriptif untuk mengumpulkan data dan informasi di PDAM Tirta Dharma kota Pasuruan, khususnya data distribusi air dari tahun 2019 sampai dengan tahun 2021. Ada beberapa tahapan yang harus dilalui dalam memprediksi distribusi air PDAM. Langkah pertama adalah menormalisasi data input. Langkah selanjutnya adalah melatih jaringan syaraf tiruan untuk mendapatkan bobot terbaik dari data *training*. Kemudian melalui proses pengujian untuk melihat seberapa akurat prediksi distribusi airnya. Berikut adalah algoritma *backpropagation* untuk memprediksi distribusi air di PDAM Tirta Dharma kota Pasuruan :



Gambar 1. Flowcart Algoritma *Backpropagation*

4. HASIL DAN PEMBAHASAN

Pada bab ini, prediksi distribusi air menggunakan data yang diperoleh langsung dari PDAM Kota Pasuruan mulai tahun 2019–2021. Berdasarkan Jaringan Syaraf Tiruan (JST), data dipisahkan menjadi data *training* dan data *testing*.

Tabel 1. Data Distribusi Air PDAM Kota Pasuruan

No	Variabel	Nama Kriteria
1	X1	Tahun 2019
2	X2	Tahun 2020
	Target	Tahun 2021

Tabel 2. Data Distribusi Air PDAM Kota Pasuruan Tahun 2019-2021

Bulan	2019	2020	2021
Januari	446.304	488.788	553.695
Februari	502.215	485.982	503.604
Maret	538.642	489.229	553.946
April	516.029	489.502	544.355
Mei	523.839	489.033	557.218
Juni	51.852	489.513	546.639
Juli	533.915	568.734	555.395
Agustus	53.703	568.816	559.415
September	518.187	579.381	544.468
Oktober	525.529	570.439	555.177
November	509.231	572.533	540.879
Desember	526.205	578.235	550.511

Persamaan berikut digunakan untuk menormalisasikan data setelah dibagi menjadi data *training* dan data *testing* :

$$x' = \frac{x - \min}{\max - \min} (0,8) + 0,1$$

dimana :

x': data telah dinormalisasi

x : normalisasi data

Tabel 3. Normalisasi Data *training* dan Data *testing*

Bulan	2019	2020	2021
Januari	0.6982	0.7626	0.8610
Februari	0.7830	0.7584	0.7851
Maret	0.8382	0.7633	0.8614
April	0.8039	0.7637	0.8469
Mei	0.8158	0.7630	0.8664
Juni	0.1000	0.7637	0.8503
Juli	0.8311	0.8839	0.8636
Agustus	0.1028	0.8840	0.8697
September	0.8072	0.9000	0.8471
Oktober	0.8183	0.8864	0.8633
November	0.7936	0.8896	0.8416
Desember	0.8194	0.8983	0.8562

Dalam penelitian ini digunakan model arsitektur jaringan syaraf tiruan 4-2-1, 4-4-1, 4-8-1. Kode dibawah ini menunjukkan hasil dari arsitektur *training* dan *testing* terbaik :

```
>> hidden_layer1=4;
>> hidden_layer2=2;
>> output=1;
>> net=newff(minmax(data_latih),[hidden_layer1,hidden_layer2,output],{'logsig','logsig','purelin'},'traingdx');
>> net.performFcn = 'mse';
>> net.trainParam.goal = 0.001;
>> net.trainParam.show = 20;
>> net.trainParam.epochs = 1000;
>> net.trainParam.mc = 0.95;
>> net.trainParam.lr = 0.1;
>> [net_keluaran,tr,Y,E] = train(net,data_latih,target_latih);
>> b=sim(net,data_uji,[],[],target_uji);
```

Tabel 4. Akurasi Data *Training* dan Data *Testing* Model Arsitektur 4-2-1

Data Training				Data Testing				Hasil
Target	Output	Error	SSE	Target	Output	Error	SSE	
0.7626	0.8610	-0.0984	0.00967849	0.8610	1.0562	-0.1951	0.03807758	1
0.7584	0.9150	-0.1567	0.02454708	0.7851	0.9985	-0.2134	0.04555603	1
0.7633	0.9051	-0.1418	0.02011308	0.8614	0.9066	-0.0452	0.00204355	1
0.7637	0.9606	-0.1969	0.03876683	0.8469	1.0270	-0.1801	0.03243654	1
0.7630	0.8213	-0.0583	0.00340402	0.8664	1.0709	-0.2045	0.04183293	1
0.7637	0.7892	-0.0255	0.00065161	0.8503	1.0204	-0.1700	0.02891219	1
0.8839	0.9023	-0.0184	0.00033846	0.8636	1.0701	-0.2065	0.04264925	1
0.8840	1.0482	-0.1642	0.02696130	0.8697	1.0664	-0.1967	0.03867230	1
0.9000	1.0632	-0.1632	0.02665040	0.8471	1.0824	-0.2354	0.05540013	1
0.8864	0.9895	-0.1031	0.01062539	0.8633	1.0438	-0.1805	0.03257276	1
0.8896	1.0624	-0.1728	0.02986988	0.8416	1.0650	-0.2233	0.04988206	1
0.8983	1.0477	-0.1495	0.02233907	0.8562	1.0567	-0.2004	0.04017434	1
		Total SSE	0.21394561			Total SSE	0.44820965	100
		MSE	0.00099953			MSE	0.00240862	

target didapatkan dari normalisasi tahun 2020, output didapatkan dari *training* dengan parameter yang telah ditentukan menggunakan software Matlab R2016a, nilai error didapatkan dari hasil pengurangan nilai target dengan nilai output, nilai SSE didapatkan melalui hasil kuadrat error yang sudah diperoleh, nilai MSE didapatkan dengan membandingkan nilai SSE dengan jumlah total pola, nilai hasil merupakan benar (1) dan salah (0) suatu pola. Persentase akurasi didapatkan dengan membandingkan nilai hasil dengan jumlah keseluruhan pola.

Tabel 5. Rekapitulasi Model Arsitektur

Arsitektur	Training		Testing	
	Epoch	MSE	MSE	Akurasi
4-2-1	410	0.00099953	0.00240862	100
4-4-1	391	0.00099922	0.00368693	75
4-8-1	652	0.00097878	0.00782414	25

Pada tabel 5 di atas dapat ditunjukkan model arsitektur terbaik 4-2-1 untuk prediksi tahun 2022 dengan epoch 410 iterasi, MSE *training* 0.00099953 dan MSE *testing* 0.00240862 dengan tingkat akurasi 100%.

Data awal digunakan pada *training* dalam proses prediksi distribusi air pada tahun yang akan datang. Namun untuk proses prediksi, digunakan data *testing* dengan model arsitektur terbaik pada software Matlab R2016a untuk menentukan seberapa akurat model arsitektur terbaik tersebut.

Adapun untuk mencari hasil prediksi sebagai hasil distribusi air di tahun yang akan datang dengan menggunakan persamaan berikut :

$$\text{prediksi} = \frac{(\text{target prediksi}-0,1)(b-a)}{0,8} + a$$

Keterangan :

a : data minimum

b : data maksimum

Tabel 6. Hasil Prediksi Distribusi Air Tahun 2022

Data Real (2021)	Target	Target Prediksi	Prediksi
553.695	0.8610	1.0562	570.310
503.604	0.7851	0.9985	566.288
553.946	0.8614	0.9066	559.877
544.355	0.8469	1.0270	568.273
557.218	0.8664	1.0709	571.339
546.639	0.8503	1.0204	567.813
555.395	0.8636	1.0701	571.284
559.415	0.8697	1.0664	571.021
544.468	0.8471	1.0824	572.141
555.177	0.8633	1.0438	569.445
540.879	0.8416	1.0650	570.922
550.511	0.8562	1.0567	570.343

Tabel 7. Rekapitulasi Model Arsitektur 4-2-1

Tahun	Training		Testing	
	Epoch	MSE	MSE	Akurasi
2023	999	0.00188878	0.02720151	100
2024	578	0.00099987	0.00053177	100
2025	1000	0.00130128	0.00090659	100

Pada tabel 7. diatas dapat disimpulkan bahwa model arsitektur 4-2-1 untuk prediksi tahun 2023 dengan *epoch* 999 iterasi, MSE *training* 0.00188878 dan MSE *testing* 0.02720151 dengan tingkat akurasi 100%. Untuk prediksi tahun 2024 dengan *epoch* 578 iterasi, MSE *training* 0.00099987 dan MSE *testing* 0.00053177 dengan tingkat akurasi 100%. Untuk prediksi tahun 2025 dengan *epoch* 1000 iterasi, MSE *training* 0.00130128 dan MSE *testing* 0.00090659 dengan tingkat akurasi sebesar 100%.

Tabel 8. Hasil Prediksi Distribusi Air Tahun 2023

Data Real (2022)	Target	Target Prediksi	Prediksi
570.310	0.8223	0.8204	570.921
566.288	0.7879	0.8606	571.536
559.877	0.7329	0.8367	571.171
568.273	0.8049	0.8833	571.885
571.339	0.8311	0.8323	571.103
567.813	0.8009	0.8874	571.947
571.284	0.8306	0.9282	572.574
571.021	0.8284	0.8685	571.658
572.141	0.8380	0.9169	572.400
569.445	0.8149	0.9865	573.467
570.922	0.8275	0.9600	573.062
570.343	0.8226	0.9724	573.250

Tabel 9. Hasil Prediksi Distribusi Air Tahun 2024

Data Real (2023)	Target	Target Prediksi	Prediksi
570.921	0.8708	0.8694	573.370
571.536	0.8779	0.7268	572.916
571.171	0.8737	0.8126	573.189
571.885	0.8819	0.8338	573.256
571.103	0.8729	0.8355	573.262
571.947	0.8826	0.9106	573.501
572.574	0.8898	0.8588	573.336
571.658	0.8793	0.9479	573.619
572.400	0.8878	0.8476	573.300
573.467	0.9000	0.8997	573.466

573.062	0.8954	0.9255	573.548
573.250	0.8975	0.9223	573.538

Tabel 10. Hasil Prediksi Distribusi Air Tahun 2025

Data Real (2024)	Target	Target Prediksi	Prediksi
573.370	0.8365	1.0414	572.412
572.916	0.8318	0.8829	572.385
573.189	0.8285	0.8893	572.386
573.256	0.8332	0.9504	572.397
573.262	0.8321	1.0805	572.419
573.501	0.8331	1.0767	572.418
573.336	0.8314	0.9933	572.404
573.619	0.8330	0.9507	572.397
573.300	0.8319	0.9037	572.389
573.466	0.8324	0.9172	572.391
573.548	0.8325	0.9254	572.392
573.538	0.8322	0.9415	572.395

Pada tabel 6, 8, 9, dan 10 di atas merupakan tahapan-tahapan melakukan prediksi distribusi air pada tahun 2022-2025. Adapun penjelasannya, data real adalah data *testing* dari data distribusi air tahun sebelumnya, target adalah normalisasi data *testing* tahun sebelumnya. Hasil keluaran jaringan yang diperoleh dengan menggunakan software Matlab R2016a sebagai target prediksi, dan hasil prediksi didapat dari hasil persamaan yang telah ditentukan. Hasil prediksi yang digunakan sebagai acuan distribusi air pada tahun 2022 hingga 2025 dengan tingkat akurasi 100% yang diperoleh dari model arsitektur terbaik yaitu model 4-2-1.

Tabel 11. Hasil dari Perbandingan Tahun 2019-2025

Bulan	Jumlah Distribusi						
	2019	2020	2021	2022	2023	2024	2025
Januari	446.304	488.788	553.695	570.310	571.480	572.388	572.412
Februari	502.215	485.982	503.604	566.288	572.123	572.308	572.385
Maret	538.642	489.229	553.946	559.877	572.223	572.252	572.386
April	516.029	489.502	544.355	568.273	572.017	572.333	572.397
Mei	523.839	489.033	557.218	571.339	572.176	572.313	572.419
Juni	51.852	489.513	546.639	567.813	572.191	572.330	572.418
Juli	533.915	568.734	555.395	571.284	572.181	572.301	572.404
Agustus	53.703	568.816	559.415	571.021	572.185	572.328	572.397
September	518.187	579.381	544.468	572.141	572.177	572.311	572.389
Oktober	525.529	570.439	555.177	569.445	572.15	572.318	572.391
November	509.231	572.533	540.879	570.922	572.228	572.320	572.392
Desember	526.205	578.235	550.511	570.343	572.227	572.315	572.395
Jumlah	5.245.651	6.370.185	6.565.302	6.829.056	6.865.358	6.867.817	6.868.785

Berdasarkan tabel 11, jumlah distribusi air mengalami peningkatan dari tahun ke tahun. Penulis melakukan prediksi untuk 4 tahun kedepan. Namun model arsitektur terbaik yaitu 4-2-1, dalam hal ini prediksi dengan tingkat akurasi 100% dapat dijadikan acuan atau tidak dengan menerapkan algoritma *backpropagation*.

5. KESIMPULAN

Berdasarkan data *training* dan *testing*, penelitian jaringan saraf tiruan (JST) *backpropagation* dapat memprediksi distribusi air PDAM Tirta Dharma kota Pasuruan tahun berikutnya. Arsitektur terbaik 4-2-1 dengan tingkat akurasi 100%, learning rate 0.1, target error 0.001, dan epoch maksimum 1000, didapat model arsitektur yaitu 4-2-1, 4-4-1, dan 4-8-1 setelah pelatihan dan pengujian. Prediksi jumlah distribusi air PDAM Tirta Dharma kota Pasuruan pada tahun 2022 sebanyak 6.829.056; pada tahun 2023 sebanyak 6.865.358, pada tahun 2024 sebanyak 6.867.817, dan pada tahun 2025 sebanyak 6.868.785.

DAFTAR PUSTAKA

- [1] Evi Duwi Agustriani, "Pendidikan Sejarah, Jurusan," *J. Pendidik. Sej.*, vol. 5, no. 1, 2017, [Online]. Available: www.pu.go.id,
- [2] UIN Antasari Banjarmasin, "BAB IV Paparan Data dan Pembahasan," *Etheses.Iainmadura.Ac.Id*, no. Mi, pp. 101–140, 2017, [Online]. Available: <https://doi.org/10.31219/osf.io/ns2rw>
- [3] Nurfalinda, E. Oktafiansyah, and A. Uperiati, "Prediksi Pendistribusian Air di Perusahaan Daerah Air Minum (PDAM) dengan Metode Adaptive Neuro Fuzzy Inference System (ANFIS)," *J. Sustain. J. Has. Penelit. dan Ind. Terap.*, vol. 10, no. 1, pp. 32–36, 2021, doi: 10.31629/sustainable.v10i1.1404.
- [4] D. Nuraziza, *Peramalan Metode Box-Jenkins Untuk Memprediksi Banyaknya Air Bersih Yang Disalurkan Pdam Di Pekanbaru*. Universitas Islam Negeri Sultan Syarif Kasim Riau, 2022.
- [5] D. Jauhari, A. Himawan, and C. Dewi, "Prediksi Distribusi Air PDAM Menggunakan Metode Jaringan Syaraf Tiruan

- Backpropagation Di PDAM Kota Malang,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 2, p. 83, 2016, doi: 10.25126/jtiik.201632155.
- [6] A. F. Setiawan and A. K. Agung, “Klasifikasi Pola Sidik Jari Menggunakan Jaringan Syaraf Tiruan Backpropagation Untuk Analisa Karakteristik Seseorang,” *Antivirus J. Ilm. Tek. Inform.*, vol. 10, no. 2, pp. 50–55, 2016, doi: 10.35457/antivirus.v10i2.162.
- [7] A. P. Windarto, M. R. Lubis, and Solikhun, “Model Arsitektur Neural Network Dengan Backpropagation Pada Prediksi Total Laba,” *Kumpul. J. Ilmu Komput.*, vol. 05, no. 02, pp. 147–158, 2018.
- [8] R. N. Putri and D. Setiawan, “Prototipe Pakan Ayamotomatis Menggunakan Metode Backpropagationberbasis Jaringan Syaraf Tiruan,” *JOISIE (Journal Inf. Syst. Informatics Eng.*, vol. 2, no. 1, p. 45, 2019, doi: 10.35145/joisie.v2i1.250.
- [9] H. Pratiwi and K. Harianto, “Perbandingan Algoritma ELM Dan Backpropagation Terhadap Prestasi Akademik Mahasiswa,” *J-SAKTI (Jurnal Sains Komput. dan Inform.*, vol. 3, no. 2, p. 282, 2019, doi: 10.30645/j-sakti.v3i2.147.
- [10] B. Satria, “Prediksi Volume Penggunaan Air PDAM Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 2, no. 3, pp. 674–684, 2018, doi: 10.29207/resti.v2i3.575.
- [11] H. Jaya *et al.*, *Kecerdasan Buatan*, vol. 53, no. 9, 2018.
- [12] M. Rahul, I. Gunawan, F. Anggraini, S. Sumarno, and I. O. Kirana, “Analisa JST Untuk Memprediksi Pembuatan SIM Menggunakan Metode Algoritma Backpropagation,” *J. Media Inform. Budidarma*, vol. 4, no. 1, p. 124, 2020, doi: 10.30865/mib.v4i1.1742.
- [13] S. R. Suhartanto, C. Dewi, and L. Muflikhah, “Implementasi Jaringan Syaraf Tiruan Backpropagation untuk Mendiagnosis Penyakit Kulit pada Anak,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 1, no. 7, pp. 555–562, 2017, [Online]. Available: <http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/163>
- [14] L. Sinaga, E. Irawan, and W. Saputra, “Penerapan Jaringan Saraf Tiruan Metode Backpropagation Dalam Memprediksi Distribusi Air Pada PDAM Tirtauli Kota Pematangsiantar,” *Pros. Semin. Nas. dan Inf. Sci.*, vol. 2, pp. 161–168, 2020.
- [15] B. K. Sihotang and A. Wanto, “Analisis Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Tamu Pada Hotel Non Bintang,” *Techno.COM*, vol. 17, no. 4, pp. 333–346, 2018.
- [16] Y. D. Lestari, “Jaringan Syaraf Tiruan Untuk Prediksi Penjualan Jamur Menggunakan Algoritma Backpropagation,” *J. ISD*, vol. 2, no. 1, pp. 2477–863, 2017.
- [17] P. I. Putra, I. M. D. U., Gandhiadi, G., & Harini, L., “Implementasi Bacpropagation Neural Network dalam Prakiraan Cuaca di daerah Bali Selatan,” *E-Jurnal Mat.*, no. 5, p. 126132, 2016.