Jurnal Sains Matematika dan Statistika
p-ISSN: 2460-4542
e-ISSN: 2615-8663

Penerapan Algoritma Backpropagation dalam Memprediksi Tingkat Penghunian Kamar Hotel Nonbintang di Provinsi Kepulauan Bangka Belitung

Aulia Febiola[1], Ineu Sulistiana[2], Ririn Amelia[3]

[1,2,3] Program Studi Matematika, Universitas Bangka Belitung
Jl. Kampus Terpadu Balunijuk, Provinsi Kepulauan Bangka Belitung, 33172
Email: auliafebiyola1@gmail.com[1], ineu.sastrawinangun90@gmail.com[2], ririn-amelia@ubb.ac.id[3]
Korespondensi penulis : auliafebiyola1@gmail.com

Submitted : 7 Mei 2025 Accepted : 7 Juni 2026 Publish : 30 Juli 2026

Abstrak

Penelitian ini bertujuan untuk mengetahui hasil prediksi TPK hotel nonbintang di Provinsi Kepulauan Bangka Belitung. Penelitian ini menggunakan algoritma *backpropagation* yang dikenal sederhana namun efektif dan memiliki tingkat akurasi yang tinggi. Hasil dari penelitian ini menunjukkan bahwa arsitektur jaringan *backpropagation* terbaik untuk memprediksi TPK hotel nonbintang adalah arsitektur jaringan 60-41-1 dengan MAPE pada fase pelatihan sebesar 12,89 persen dan MAPE pada fase pengujian sebesar 9,96 persen. Berdasarkan hasil penelitian, pemerintah daerah dapat mengambil kebijakan guna mengoptimalkan potensi pendapatan sektor perhotelan dan pengusaha hotel dapat menerapkan inovasi atau promo paket wisata untuk menarik pengunjung.

Kata Kunci: Hotel, tingkat penghunian kamar, algoritma *backpropagation*, prediksi, pariwisata

Abstract

This study aims to determine the results of predicting the room occupancy rate of non-starred hotels in the Bangka Belitung Islands Province. This study uses the backpropagation algorithm, which is known to be simple but effective and has a high level of accuracy. The results of this study indicate that the best backpropagation network architecture for predicting the room occupancy rate of non-starred hotels is the 60-41-1 network architecture with a MAPE in the training phase of 12.89 percent and a MAPE in the testing phase of 9.96 percent. Based on the results of the study, local governments can adopt policies to optimize the potential revenue of the hotel sector, and hotel entrepreneurs can implement innovations or tour package promotions to attract visitors.

***Keywords*:** *Hotel, room ocuppancy rate, backpropagation algorithm, predict, tourism*

 License: CC BY-NC-SA

1. Pendahuluan

Sektor pariwisata merupakan salah satu sektor ekonomi yang mengalami pertumbuhan pesat dan menjadi salah satu penyumbang utama terhadap perekonomian nasional. Pertumbuhan sektor ini di suatu daerah dapat diamati melalui indikator seperti jumlah kunjungan wisatawan yang diperoleh dari data jumlah tamu yang menginap di hotel. Pada tahun 2023, Provinsi Kepulauan Bangka Belitung mencatatkan jumlah tamu menginap sebanyak 5.046 wisatawan mancanegara dan 635.080 wisatawan domestik [1]. Hal ini memberikan keuntungan karena sektor perhotelan menjadi indikator keberhasilan suatu daerah dalam menarik sekaligus memperkenalkan daerah kepada wisatawan. Salah satu indikator utama dalam industri perhotelan untuk menilai daya tarik suatu destinasi adalah Tingkat Penghunian Kamar (TPK).

Menurut Badan Pusat Statistik (BPS) Indonesia, TPK dibedakan menjadi dua kategori, yaitu hotel bintang dan hotel nonbintang. Hotel bintang adalah jenis usaha akomodasi jangka pendek yang memenuhi standar dan kriteria khusus. Sedangkan hotel nonbintang adalah jenis penginapan yang memanfaatkan bangunan atau sebagian bangunan untuk menyediakan layanan bagi tamu [2]. Sementara itu, TPK hotel merupakan persentase jumlah kamar yang ditempati atau disewa dibandingkan dengan total kamar yang tersedia di hotel [3]. Selain merepresentasikan tingkat popularitas suatu hotel, TPK juga mencerminkan situasi dan dinamika industri pariwisata di suatu daerah dan mampu memberikan gambaran mengenai performa ekonomi serta daya tarik destinasi wisata bagi para pengunjung [4]. Berdasarkan BPS Provinsi Kepulauan Bangka Belitung TPK hotel nonbintang pernah mencapai puncak di angka 62,14 persen yang merupakan nilai tertinggi selama periode tersebut. Fakta ini seharusnya menjadi perhatian bagi para pemangku kepentingan sektor pariwisata dalam rangka mendorong peningkatan TPK hotel nonbintang. Ketidakstabilan nilai TPK ini berpotensi memengaruhi kebijakan yang diambil oleh instansi pemerintah, pihak swasta, pelaku usaha perhotelan, serta para investor di Bangka Belitung [5]. Oleh karena itu, guna membantu pengambilan keputusan baik dalam mengantisipasi peningkatan maupun penurunan TPK hotel nonbintang, diperlukan adanya prediksi terhadap TPK di masa yang akan datang melalui penyediaan informasi serta identifikasi potensi risiko.

Prediksi dapat membantu memanfaatkan sumber daya dengan lebih efektif karena prediksi dapat meminimalisir risiko melalui proses memperkirakan kondisi masa depan dengan memanfaatkan data historis [6]. Terdapat berbagai metode yang dapat digunakan untuk melakukan prediksi. Namun, sekarang ini, model jaringan saraf tiruan sedang populer digunakan karena dapat mengidentifikasi pola dan hubungan nonlinier melampaui metode tradisional serta memperbaiki kinerja model [7]. Jaringan Saraf Tiruan (JST) terbukti sebagai model yang sangat baru dan bermanfaat yang diterapkan pada pemecahan masalah dan pembelajaran mesin [8]. JST merupakan salah satu cabang dari kecerdasan buatan yang memiliki fungsi, seperti pengenalan pola, prediksi, klasifikasi, pemodelan fungsi, hingga proses optimasi [9].

Salah satu algoritma JST yang paling dikenal adalah *backpropagation*, yaitu metode pelatihan yang digunakan untuk jaringan saraf berlapis banyak (*multilayer*) secara terarah [10][11][12]. Algoritma *backpropagation* didasarkan pada prinsip-prinsip matematis yang kuat dengan melibatkan dan penentuan koefisien dengan cara meminimalkan jumlah

kuadrat dari kesalahan hingga tingkat presisi tertentu tercapai [13][14]. Algoritma ini banyak digunakan untuk prediksi karena fleksibilitasnya dalam menangkap hubungan nonlinier dengan baik [15][16][17]. Oleh karena itu, algoritma ini dikenal sebagai metode yang sederhana namun efektif dengan kemampuan menghasilkan tingkat akurasi yang tinggi [18]. Selain itu, algoritma ini juga menawarkan keseimbangan antara akurasi prediksi, efisiensi komputasi, dan stabilitas model [19].

Namun, *error* dalam prediksi bisa muncul akibat kesalahan dalam proses prediksi yang dapat diketahui dengan melakukan perbandingan antara hasil prediksi dengan data aktual. *Mean Absolute Percentage Error* (MAPE) merupakan ukuran rata-rata perbedaan absolut antara hasil prediksi terhadap nilai aktual dalam bentuk persentase [20][21]. Dalam hal ini, MAPE dapat digunakan untuk menilai seberapa akurat model dalam memprediksi hasil yang sebenarnya [22][23][24]. Selain itu, MAPE memiliki kriteria interpretasi nilai yang memberikan pemahaman jelas dan mudah dibandingkan dengan ukuran kesalahan prediksi lainnya [20]. MAPE juga memberikan perspektif tentang kesalahan yang tidak bergantung pada skala [25].

Beberapa penelitian terdahulu yang berkaitan dengan penelitian ini adalah penelitian [26] yang menunjukkan bahwa model *sarimax* lebih unggul daripada *prophet* dalam memprediksi TPK hotel di Jawa Tengah. Selain itu, penelitian [27] yang menggunakan algoritma *backpropagation* untuk memprediksi jumlah penduduk di Siantar Martoba dengan arsitektur jaringan saraf terbaiknya adalah 4-31-1 dan menghasilkan nilai MSE pelatihan sebesar 0,0000996 dan MSE pengujian sebesar 0,000099957. Terdapat penelitian lain [28] yang memprediksi harga telur ayam menggunakan algoritma *backpropagation* dengan nilai MAPE yang dihasilkan oleh arsitektur jaringan sebesar 15 persen.

Keterbaruan dalam penelitian ini terletak pada penerapan algoritma *backpropagation* khususnya pada data TPK hotel nonbintang dengan dataset kecil. Meskipun algoritma *backpropagation* merupakan metode klasik dalam pelatihan JST, penelitian [29] menunjukkan bahwa model JST masih relevan untuk memprediksi TPK hotel dengan data historis yang relatif terbatas dan variabel numerik sederhana. Selain itu, dalam studi lain [30] dilakukan prediksi TPK hotel menggunakan beberapa model JST termasuk *backpropagation*.

2. Metode Penelitian

Jenis data yang digunakan dalam penelitian ini adalah data sekunder berupa data runtun waktu. Menurut [31], data runtun waktu merupakan serangkaian data yang tersusun berdasarkan waktu secara berurutan. Data sekunder ini bersumber dari *website* resmi Badan Pusat Statistik (BPS) Provinsi Kepulauan Bangka Belitung. Data yang digunakan adalah data TPK hotel nonbintang periode bulan Januari 2012 sampai dengan Juli 2024 dan berjumlah 151 data. Penelitian ini menggunakan teknik studi literatur yang merupakan teknik atau cara dalam mengumpulkan data melalui penelusuran sumber media yang memuat data atau informasi yang diperlukan [32].

Algoritma *backpropagation* dipilih sebagai teknik analisis data pada penelitian ini. Algoritma ini disebut *backpropagation* [33] karena kesalahan *output* yang dihasilkan akan merambat mundur dan kembali ke lapisan tersembunyi hingga kesalahan minimum tercapai. Algoritma ini memanfaatkan arsitektur *multilayer* dan mekanisme pembelajaran umpan baliknya untuk mengelola hubungan kompleks secara lebih efisien sehingga

memungkinkan prediksi yang lebih akurat [34][35]. Seperti pada JST lainnya, algoritma *backpropagation* memiliki tiga lapisan (*layer*) yakni lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan keluaran (*output layer*) [18][36][37].

Algoritma *backpropagation* terdiri dari empat langkah utama yakni fase perambatan maju (*feedforward*), fase perhitungan *error*, fase perambatan mundur (*backpropagation*) dan fase update nilai bobot dan bias (*adjustment*) [34][38][39]. Terdapat banyak fungsi aktivasi seperti Tanh, ReLU, *Leaky* ReLU, *Parametric* ReLU, ELU, GELU, SELU, *Hard Sigmoid*, *Softplus*, *Softmax* dan alternatif lain seperti *Swish*, *Mish*, GCU [40][41] tetapi fungsi aktivasi sigmoid [37] adalah yang paling umum digunakan. Selain itu, terdapat pula fungsi pelatihan seperti *traingda*, *traingdx*, dan *trainrp* (perbaikan dengan teknik heuristik) dan *trainbfg*, *trainoss*, dan *trainlm* (perbaikan dengan teknik numerik) [42]. Namun, *trainlm* merupakan algoritma yang paling optimal dalam mengenali pola data [43][44]. Adapun tahapan analisis data menggunakan algoritma *backpropagation* pada penelitian ini sebagai berikut [28][45]:

1. Analisis Statistik Deskriptif
   Tahapan ini bertujuan untuk memberikan gambaran umum dari data TPK hotel nonbintang.
2. *Pre-processing* Data
   a. Normalisasi Data
   Normalisasi data dilakukan guna mempermudah algoritma *backpropagation* dalam melakukan perhitungan sehingga dapat bekerja dengan lebih efisien. Normalisasi data ini dihitung dengan rumus sebagai berikut:
   $$X' = \frac{0{,}8(x-a)}{b-a} + 0{,}1 \quad (1)$$
   dengan X' adalah hasil normalisasi data, x adalah data TPK hotel nonbintang, a adalah nilai minimum data, b adalah nilai maksimum data.
   b. Pembagian Data
   Tidak terdapat aturan yang baku mengenai proporsi pembagian data terbaik atau optimal untuk kumpulan data tertentu [46].
3. Perancangan Arsitektur Jaringan
   Arsitektur jaringan ini melibatkan *input layer*, *hidden layer*, dan *output layer*.
4. Pelatihan Data
5. Evaluasi dan Pemilihan Arsitektur Jaringan Terbaik
   Arsitektur jaringan terbaik pada penelitian ini dipilih dengan melihat nilai *error* yakni MAPE yang memiliki kriteria interpretasi nilai seperti pada Tabel 1 [47].

Tabel 1. Kriteria Interpretasi Nilai MAPE

Nilai MAPE	Kriteria
< 10%	Kemampuan prediksi sangat baik
10% - 20%	Kemampuan prediksi baik
21% - 50%	Kemampuan prediksi cukup baik
> 50%	Kemampuan prediksi buruk

6. Pengujian Data
7. Pengujian *Overfitting* dan *Underfitting* Data
   Pengujian ini dilakukan untuk melihat apakah arsitektur jaringan yang sudah dievaluasi dan dipilih menunjukkan gejala *overfitting* atau *underfitting* atau tidak keduanya.

8. Prediksi dan Denormalisasi
   Prediksi dilakukan dengan menggunakan satu arsitektur jaringan terbaik dan akan didenormalisasi guna mengembalikan data ke bentuk semula atau ke skala data asli.
9. Interpretasi Hasil

3. Hasil dan Pembahasan

3.1 Analisis Statistik Deskriptif

Analisis statistik deskriptif dari data TPK hotel nonbintang disajikan pada Tabel 2.

Tabel 2. Hasil Analisis Statistik Deskriptif Data TPK Hotel Nonbintang

Analisis Deskriptif	TPK Hotel Nonbintang
Maksimum	62,14
Minimum	10,66
Mean	22,40
Standar Deviasi	6,33
Varians	40,11

Berdasarkan Tabel 2, dapat dilihat bahwa nilai *mean* dari data TPK hotel nonbintang lebih besar daripada nilai standar deviasinya. Data tersebut dapat dikatakan kurang bervariasi karena penyebaran data tersebut relatif rendah terhadap nilai *mean* serta simpangan data tersebut dapat dikatakan baik dan tidak terdapat *outlier*.

3.2 *Pre-processing* Data

Tahapan pertama dari *pre-processing* data adalah normalisasi data. Adapun hasil normalisasi data TPK hotel nonbintang disajikan pada Tabel 3.

Tabel 3. Hasil Normalisasi Data TPK Hotel Nonbintang

Bulan-Tahun	TPK Hotel Nonbintang
Januari-2012	0,28
Februari-2012	0,31
Maret-2012	0,32
April-2012	0,32
Mei-2012	0,35
⋮	⋮
April-2024	0,17
Mei-2024	0,15
Juni-2024	0,15
Juli-2024	0,17

Tahapan selanjutnya yakni pembagian data. Pembagian data yang dihasilkan adalah 90% dari 151 yakni 136 data sebagai data *training* dan 10% dari 151 data yakni 15 data sebagai data *testing*. Dua set data tersebut dibagi lagi menjadi data *input* dan data target untuk data *training* dan data *testing*. Adapun hasil pembagian data TPK hotel nonbintang disajikan pada Tabel 4 dan Tabel 5.

Tabel 4. Hasil Pembagian Data *Input* dan Data *Target* dari Data *Training* TPK Hotel Nonbintang

Input	Pola ke-											
	1	2	3	4	5	⋯	71	72	73	74	75	76

X_1	0,28	0,31	0,32	0,32	0,35	⋯	0,33	0,39	0,21	0,25	0,31	0,34
X_2	0,31	0,32	0,32	0,35	0,40	⋯	0,39	0,21	0,25	0,31	0,34	0,25
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
X_{59}	0,38	0,40	0,38	0,39	0,90	⋯	0,19	0,18	0,21	0,23	0,16	0,16
X_{60}	0,40	0,38	0,39	0,90	0,44	⋯	0,18	0,21	0,23	0,16	0,16	0,18
t	0,38	0,39	0,90	0,44	0,44	⋯	0,21	0,23	0,16	0,16	0,18	0,17

Tabel 5. Hasil Pembagian Data *Input* dan Data *Target* dari Data *Testing* TPK Hotel Nonbintang

Input	Pola ke-											
	1	**2**	**3**	**4**	**5**	⋯	**71**	**72**	**73**	**74**	**75**	**76**
X_1	0,21	0,26	0,24	0,23	0,29	⋯	0,26	0,34	0,24	0,14	0,28	0,27
X_2	0,26	0,24	0,23	0,29	0,23	⋯	0,34	0,24	0,14	0,28	0,27	0,21
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
X_{59}	0,25	0,31	0,34	0,25	0,27	⋯	0,25	0,18	0,23	0,16	0,17	0,15
X_{60}	0,31	0,34	0,25	0,27	0,31	⋯	0,18	0,23	0,16	0,17	0,15	0,15
t	0,34	0,25	0,27	0,31	0,35	⋯	0,23	0,16	0,17	0,15	0,15	0,17

Berdasarkan Tabel 4 dan Tabel 5, dapat dilihat bahwa baik data *training* maupun data *testing* memiliki 60 *input* dan 76 pola *input* di mana setiap pola *input* memiliki 1 target.

3.3 Perancangan Arsitektur Jaringan

Perancangan arsitektur jaringan algoritma *backpropagation* dilakukan secara *trial error*. Perancangan arsitektur jaringan ini melibatkan parameter utama seperti *input layer, hidden layer,* dan *output layer*. Percobaan perancangan arsitektur jaringan dihentikan pada percobaan ke-328 karena telah ditemukan arsitektur jaringan yang tidak menunjukkan gejala *overfitting* maupun *underfitting.* Adapun hasil percobaan perancangan arsitektur jaringan pada data TPK hotel bintang dan nonbintang disajikan pada Tabel 6.

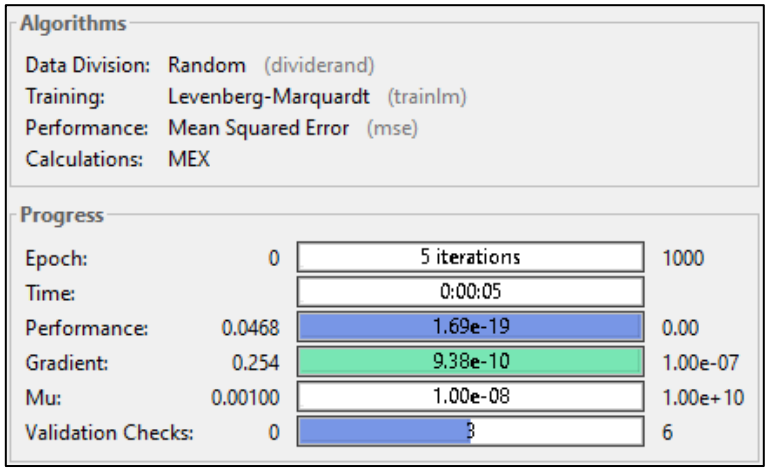
Tabel 6. Hasil Pembagian Data *Input* dan Data *Target* dari Data *Testing* TPK Hotel Nonbintang

No	Hotel Nonbintang
1	60-1-1
2	60-2-1
3	60-3-1
⋮	⋮
327	60-779-1
328	60-7455-1

Berdasarkan Tabel 6, terlihat bahwa arsitektur jaringan yang dirancang memiliki 1 *input layer* dengan 60 neuron, 1 *hidden layer* dengan beragam jumlah neuron, dan 1 *output layer* dengan 1 neuron.

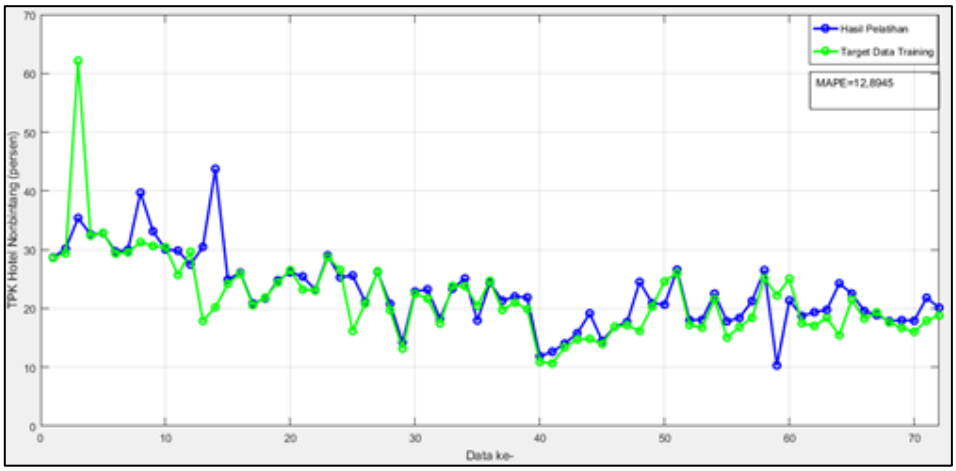
3.4 Pelatihan Data

Tahapan ini menggunakan fungsi aktivasi *sigmoid biner* pada *hidden layer* dan fungsi aktivasi *purelin* pada *output layer*. Selain itu, fungsi pelatihan yang digunakan adalah *trainlm* karena dapat mempercepat konvergensi dan lebih stabil. Adapun hasil pelatihan data menggunakan salah satu arsitektur jaringan yakni 60-41-1 disajikan pada Gambar 1.



Gambar 1. Hasil Pelatihan Data Menggunakan Arsitektur Jaringan 60-41-1

Berdasarkan Gambar 1, hasil pelatihan menunjukkan bahwa proses berhenti pada iterasi ke-5 dalam waktu 5 detik dengan nilai *gradient* $9{,}38\times10^{-10}$. *Performance* pada awal iterasi adalah 0,0468 dan mengalami penurunan seiring iterasi hingga mencapai nilai $1{,}69\times10^{-19}$ yang menunjukkan bahwa arsitektur jaringan sudah mengalami banyak perbaikan serta semakin baik dalam memprediksi data. Selain itu, nilai *gradient* pada awal iterasi yakni 0,254 turun menjadi $9{,}38\times10^{-10}$ yang menunjukkan bahwa arsitektur jaringan telah mengalami perubahan dalam bobot dan bias yang kecil dan telah mendekati konvergensi serta *error* antara hasil pelatihan dengan target data *training* telah minimal. Faktor *damping* (Mu) juga mengalami perubahan dari nilai sebesar 0,00100 menjadi $1{,}00\times10^{-8}$ untuk menyesuaikan kecepatan konvergensi dari arsitektur jaringan. Selanjutnya, disajikan grafik perbandingan hasil pelatihan dengan target data *training* dari hasil pelatihan data menggunakan arsitektur jaringan 60-41-1 pada Gambar 2.



Gambar 2. Grafik Perbandingan Hasil Pelatihan dengan Target Data *Training*

Gambar 2 menunjukkan bahwa secara umum hasil pelatihan dengan arsitektur jaringan 60-41-1 mampu mengikuti pola dari target data *training*. Namun, terdapat pula perbedaan pada titik-titik ekstrem di mana hasil pelatihan tidak dapat mengikuti pola perubahan yang tajam. Hal ini mengindikasikan bahwa arsitektur jaringan kemungkinan mengalami kesulitan dalam menangkap perubahan data yang mendadak dan belum

sepenuhnya memahami pola data. Namun, secara umum, pola keseluruhan masih terjaga sehingga arsitektur jaringan ini masih dapat memberikan prediksi yang baik. Hal ini juga diperkuat dengan nilai MAPE pada fase pelatihan tersebut sebesar 12,89 persen.

3.5 Evaluasi dan Pemilihan Arsitektur Jaringan Terbaik

Tahapan ini menggunakan indikator MAPE terendah untuk menentukan 22 arsitektur jaringan terbaik dari 28 sesi percobaan perancangan arsitektur jaringan. Adapun 22 arsitektur jaringan tersebut disajikan pada Tabel 7.

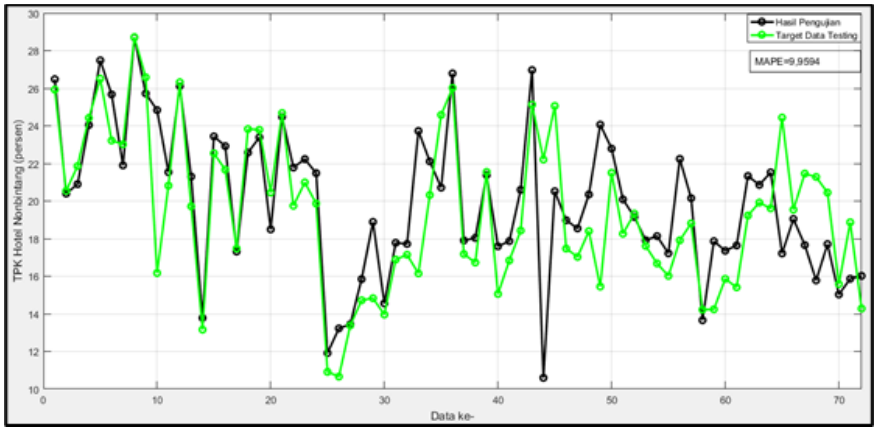
Tabel 7. Arsitektur Jaringan Terbaik dari 22 Sesi Percobaan Perancangan Arsitektur Jaringan TPK Hotel Nonbintang

No	Arsitektur Jaringan	No	Arsitektur Jaringan	No	Arsitektur Jaringan	No	Arsitektur Jaringan	No	Arsitektur Jaringan
1	60-3-1	6	60-17-1	11	60-35-1	15	60-45-1	19	60-56-1
2	60-5-1	7	60-19-1	12	60-41-1	16	60-49-1	20	60-86-1
3	60-6-1	8	60-23-1	13	60-42-1	17	60-53-1	21	60-125-1
4	60-8-1	9	60-26-1	14	60-43-1	18	60-55-1	22	60-7455-1
5	60-14-1	10	60-27-1						

Berdasarkan Tabel 7, terlihat bahwa arsitektur jaringan terbaik dari setiap sesi percobaan memiliki jumlah neuron yang bervariasi di *hidden layer*-nya.

3.6 Pengujian Data

Tahapan ini dilakukan desngan menggunakan 22 arsitektur jaringan terbaik yang telah dievaluasi dan dipilih pada tahapan sebelumnya. Adapun hasil pengujian data berupa grafik perbandingan hasil pengujian dengan target data *testing* menggunakan salah satu arsitektur jaringan yakni arsitektur jaringan 60-41-1 disajikan pada Gambar 4.



Gambar 3. Grafik Perbandingan Hasil Pengujian dengan Target Data *Testing*

Berdasarkan Gambar 3, menunjukkan bahwa secara umum hasil pengujian dengan arsitektur jaringan 60-41-1 mampu mengikuti pola dari target data *testing*. Namun, terdapat pula perbedaan pada titik-titik ekstrem di mana hasil pengujian tidak dapat mengikuti pola perubahan yang tajam. Hal ini dapat terjadi karena arsitektur jaringan kemungkinan mengalami kesulitan dalam menangkap perubahan data yang mendadak dan belum

sepenuhnya memahami pola data. Namun, secara umum, pola keseluruhan masih terjaga sehingga arsitektur jaringan ini masih dapat memberikan prediksi yang sangat baik. Hal ini juga diperkuat dengan nilai MAPE pada fase pelatihan tersebut sebesar 9,96 persen.

3.7 Pengujian *Overfitting* dan *Underfitting* Data

Tahapan pengujian ini dilakukan dengan membandingkan nilai *error* arsitektur jaringan pada fase pelatihan data dengan nilai *error* arsitektur jaringan pada fase pengujian data. Hal ini untuk melihat arsitektur jaringan menunjukkan gejala *overfitting* atau *underfitting* atau tidak keduanya. Adapun hasil perbandingan nilai *error* arsitektur jaringan data TPK hotel nonbintang pada fase pelatihan dan pengujian data disajikan pada Tabel 8.

Tabel 8. Nilai MAPE Arsitektur Jaringan pada Fase Pelatihan dan Pengujian Data TPK Hotel Nonbintang

No	Arsitektur Jaringan	Pelatihan	Peng-ujian	Selisih	No	Arsitektur Jaringan	Pelatihan	Peng-ujian	Selisih
1	60-3-1	19,50	17,12	-2,37	12	60-41-1	12,89	9,96	-2,94
2	60-5-1	26,83	17,33	-9,50	13	60-42-1	13,56	10,48	-3,08
3	60-6-1	29,07	30,18	1,12	14	60-43-1	17,99	17,57	-0,42
4	60-8-1	17,51	26,83	9,32	15	60-45-1	25,60	25,84	0,24
5	60-14-1	60,42	64,27	3,85	16	60-49-1	58,59	73,00	14,41
6	60-17-1	16,57	38,87	22,30	17	60-53-1	60,42	64,27	3,85
7	60-19-1	8,02	13,87	5,86	18	60-55-1	11,43	18,00	6,57
8	60-23-1	19,18	17,64	-1,54	19	60-56-1	17,51	60,02	42,52
9	60-26-1	$12{,}56\times10^{-12}$	8,80	8,80	20	60-86-1	$16{,}93\times10^{-11}$	8,74	8,74
10	60-27-1	58,60	73,00	14,41	21	60-125-1	3,43	9,91	6,48
11	60-35-1	26,07	26,92	0,85	22	60-7455-1	20,85	27,86	7,01

Berdasarkan Tabel 8, disimpulkan bahwa terdapat 6 arsitektur jaringan yang dapat digunakan untuk memprediksi TPK hotel nonbintang. Namun, dikarenakan dalam penelitian ini hanya membutuhkan 1 arsitektur jaringan terbaik yang akan digunakan untuk memprediksi TPK hotel nonbintang, maka dipilihlah arsitektur jaringan 60-41-1. Hal ini karena selain arsitektur jaringan tersebut tidak terindikasi mengalami *overfitting* dan *underfitting*, arsitektur jaringan 60-41-1 ini juga memiliki nilai MAPE pelatihan dan pengujian terkecil dibandingkan dengan 5 arsitektur jaringan lainnya.

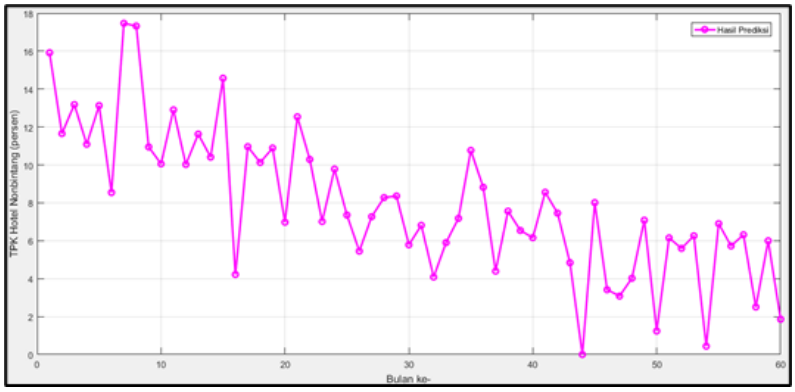
3.8 Prediksi dan Denormalisasi

Prediksi dilakukan dengan menggunakan arsitektur jaringan terbaik yang telah dipilih menggunakan indikator MAPE yakni 60-41-1 dalam jangka waktu lima tahun mulai dari Agustus 2024 sampai dengan Juli 2029. Apabila hasil prediksi telah diperoleh, nilai tersebut akan didenormalisasi guna mengembalikan data ke bentuk semula atau ke skala data asli. Adapun hasil prediksi TPK hotel nonbintang yang telah didenormalisasi disajikan pada Tabel 9 dan Gambar 4.

Tabel 9. Hasil Prediksi TPK Hotel Nonbintang yang Sudah di Denormalisasi

Bulan-Tahun	Hasil Prediksi	Bulan-Tahun	Hasil Prediksi	Bulan-Tahun	Hasil Prediksi
Agustus-2024	15,92	Agustus-2024	15,92	Agustus-2024	15,92
September-2024	11,66	September-2024	11,66	September-2024	11,66

Oktober-2024	13,18	Oktober-2024	13,18	Oktober-2024	13,18
November-2024	11,09	November-2024	11,09	November-2024	11,09
Desember-2024	13,13	Desember-2024	13,13	Desember-2024	13,13
Januari-2025	8,54	Januari-2025	8,54	Januari-2025	8,54
Februari-2025	17,47	Februari-2025	17,47	Februari-2025	17,47
Maret-2025	17,33	Maret-2025	17,33	Maret-2025	17,33
April-2025	10,95	April-2025	10,95	April-2025	10,95
Mei-2025	10,06	Mei-2025	10,06	Mei-2025	10,06
Juni-2025	12,90	Juni-2025	12,90	Juni-2025	12,90
Juli-2025	10,03	Juli-2025	10,03	Juli-2025	10,03
Agustus-2025	11,62	Agustus-2025	11,62	Agustus-2025	11,62
September-2025	10,41	September-2025	10,41	September-2025	10,41
Oktober-2025	14,57	Oktober-2025	14,57	Oktober-2025	14,57
Agustus-2024	15,92	Agustus-2024	15,92	Agustus-2024	15,92



Gambar 4. Grafik Perbandingan Hasil Pengujian dengan Target Data *Testing*

Berdasarkan Tabel 9 dan Gambar 4, terlihat bahwa hasil prediksi TPK hotel nonbintang tertinggi terdapat pada bulan bulan Februari 2025 dan terendah terdapat pada bulan Maret 2028. Hasil prediksi terlihat mengalami pola fluktuasi yang cenderung turun.

3.9 Pembahasan

Berdasarkan hasil prediksi yang telah diperoleh dan ditampilkan pada Tabel 9 dan Gambar 5 terlihat bahwa pada hasil prediksi TPK hotel nonbintang mengalami pola fluktuasi periodik yang menunjukkan adanya siklus tahunan. Pola fluktuasi dari data TPK hotel nonbintang ini cenderung mengalami tren penurunan dari waktu ke waktu. Dapat dilihat bahwa TPK hotel nonbintang mengalami kenaikan pada bulan-bulan tertentu seperti pada bulan Oktober 2024, Desember 2024, Februari 2025, Oktober 2025, Desember 2025, Oktober 2026, Desember 2026, Desember 2027, Oktober 2028, Desember 2028, Februari 2029 serta penurunan seperti pada bulan September 2024, Januari 2025, November 2025, Juni 2026, September 2026, Maret 2027, Juni 2027, Agustus 2027, Maret 2028, Mei 2028, September 2028, Juli 2029. Hal ini dapat disebabkan oleh berbagai faktor seperti adanya variasi musiman, perubahan ekonomi, kebijakan pariwisata, musim liburan atau pandemi. Dibandingkan dengan penelitian [28] yang memprediksi harga telur ayam menggunakan algoritma *backpropagation* dan menghasilkan nilai MAPE sebesar 15 persen, penelitian ini mampu menghasilkan nilai MAPE pada fase pelatihan data sebesar 12,89 persen dan fase pengujian data sebesar 9,96 persen dengan arsitektur jaringan *backpropagation* terbaik yakni arsitektur jaringan 60-41-1.

4. Kesimpulan

Berdasarkan hasil penelitian ini, dihasilkan prediksi TPK hotel nonbintang menggunakan arsitektur jaringan *backpropagation* terbaik yakni arsitektur jaringan 60-41-1 dengan nilai MAPE pada fase pelatihan data sebesar 12,89 persen dan fase pengujian data sebesar 9,96 persen. Hal ini menunjukkan bahwa algoritma *backpropagation* dapat memprediksi TPK hotel nonbintang dengan baik. Dengan demikian, penelitian ini memperkuat literatur bahwa algoritma *backpropagation* masih menjadi pendekatan yang valid dalam menghadapi dataset kecil. Penelitian ini juga sekaligus memberikan kontribusi baru terkait penerapan algoritma *backpropagation* dalam bidang perhotelan dan efektivitas algoritma *backpropagation* dalam menangani karakteristik data tersebut. Selain itu, hasil penelitian ini dapat menjadi salah satu pertimbangan pemerintah daerah dan Dinas Pariwisata untuk mengambil kebijakan demi meningkatkan potensi hotel nonbintang.

Ucapan Terima Kasih

Terima kasih kepada Badan Pusat Statistik Provinsi Kepulauan Bangka Belitung yang telah menyediakan data untuk penelitian ini. Terima kasih juga kepada Dosen Pembimbing dan pihak-pihak yang telah membantu terselesaikannya artikel ilmiah ini.

Daftar Pustaka

[1] Badan Pusat Statistik Provinsi Kepulauan Bangka Belitung, "Jumlah Tamu Menginap (Hotel Bintang dan Nonbintang) (Orang), 2022-2023." Accessed: Aug. 13, 2024. [Online]. Available: https://babel.bps.go.id/id/statistics-table/2/NjcyIzI=/jumlah-tamu-menginap--hotel-bintang-dan-nonbintang---orang-.html

[2] A. Yuliati and S. Purwati, "Analisis Korelasi Antara Rata-rata Lama Tamu Menginap, Jumlah Pengunjung Obyek Wisata dan Pendapatan Domestik Regional Bruto Kabupaten Semarang," *Media Informasi Penelitian Kabupaten Semarang (SINOV)*, vol. 4, no. 1, pp. 112–119, Jun. 2022, Accessed: Aug. 29, 2024. [Online]. Available: https://doi.org/10.55606/sinov.v5i1.221

[3] Badan Pusat Statistik Indonesia, *Tingkat Penghunian Kamar Hotel Indonesia 2023*, vol. 43. Jakarta: Badan Pusat Statistik, 2024.

[4] F. Amani and Halmawati, "Pengaruh Partisipasi Anggaran dan Komitmen Organisasi terhadap Kinerja Manajerial pada Perhotelan di Kota Padang," *Jurnal Eksplorasi Akuntansi (JEA)*, vol. 4, no. 2, pp. 299–310, May 2022, Accessed: Aug. 29, 2024. [Online]. Available: http://jea.ppj.unp.ac.id/index.php/jea/article/view/528

[5] L. Pratiti and B. Nurdewanto, "Peramalan Tingkat Penghunian Kamar Hotel Berbintang di Kota Malang Menggunakan Metode Single Exponential Smoothing dan Double Exponential Smoothing," *JSI:Jurnal Sistem Informasi*, vol. 11, no. 2, pp. 211–222, 2024, Accessed: Aug. 13, 2024. [Online]. Available: https://journal.universitassuryadarma.ac.id/index.php/jsi/article/view/1255

[6] N. Istiqomah, M. A. Ridla, and N. Azise, "Data Mining: Tingkat Penghuni Kamar Hotel Di Aceh Dari Tahun 2018-2022 Menggunakan Aplikasi Zaitun," *Gudang Jurnal Multidisiplin Ilmu*, vol. 2, no. 8, pp. 9–12, Aug. 2024, doi: 10.59435/gjmi.v2i8.671.

[7] E. Arar and F. H. Halicioglu, "Understanding Artificial Neural Networks as a Transformative Approach to Construction Risk Management: A Systematic Literature Review," *Buildings*, vol. 15, no. 18, Sep. 2025, doi: 10.3390/buildings15183346.

[8] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. Mohamed, and H. Arshad, "State-of-the-art in artificial neural network applications: A survey," *Heliyon*, vol. 4, 2018, doi: 10.1016/j.heliyon.2018.

[9] J. Huang, X. Zeng, J. Fu, Y. Han, and H. Chen, "Safety Risk Assessment Using a BP Neural Network of High Cutting Slope Construction in High-Speed Railway," *Buildings*, vol. 12, no. 5, May 2022, doi: 10.3390/buildings12050598.

[10] X. Li, Q. Jiang, M. K. Hsu, and Q. Chen, "Support or Risk? Software Project Risk Assessment Model Based on Rough Set Theory and Backpropagation Neural Network," *Sustainability*, vol. 11, no. 17, Sep. 2019, doi: 10.3390/su11174513.

[11] W. Li, "Research on Project Knowledge Management Risk Early Warning Based on Bp Neural Network," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Feb. 2021. doi: 10.1088/1742-6596/1744/3/032250.

[12] S. Handayani and Solikhun, "Prediksi Angka Kelahiran Bayi di NTT Menggunakan Algoritma Backpropagation," *Jurnal JPILKOM (Jurnal Penelitian Ilmu Komputer)*, vol. 2, no. 1, pp. 26–32, Mar. 2024, Accessed: Aug. 02, 2024. [Online]. Available: https://jpilkom.org/index.php/journal/article/view/29

[13] C. F. Rodríguez-Hernández, M. Musso, E. Kyndt, and E. Cascallar, "Artificial Neural Networks in Academic Performance Prediction: Systematic Implementation and Predictor Evaluation," *Computers and Education: Artificial Intelligence*, vol. 2, Jan. 2021, doi: 10.1016/j.caeai.2021.100018.

[14] E. W. Sumantri, A. Y. Nasution, Suyono, and R. Rosnelly, "Pengenalan Pola Aksara Batak menggunakan Backpropagation," *Jurnal SISFOTENIKA*, vol. 14, no. 1, p. 57, Jan. 2024, doi: 10.30700/sisfotenika.v14i1.419.

[15] D. Cui, G. Sun, and X. Zhan, "Security Risk Management System for the Construction and Operation of Smart Port Area Based on BP Neural Network Algorithm," in *Procedia Computer Science*, Elsevier B.V., 2023, pp. 838–846. doi: 10.1016/j.procs.2023.11.111.

[16] R. Zhang and Y. Zhu, "Predicting the Mechanical Properties of Heat-Treated Woods Using Optimization-Algorithm-Based BPNN," *Forests*, vol. 14, no. 5, May 2023, doi: 10.3390/f14050935.

[17] J. Huang and Z. Kuang, "Mechanical Property Prediction of Wood Using a Backpropagation Neural Network Optimized by Adaptive Fractional-Order Particle Swarm Algorithm," *Forests*, vol. 16, no. 8, Aug. 2025, doi: 10.3390/f16081223.

[18] S. Shi, H. Zheng, H. Li, and X. Wang, "Study on the Evaluation Method of Collaborative Dust Prevention Effect with Coal Miners-based on Feature Reduction, Genetic Algorithm, and Backpropagation," *Saf. Health Work*, Dec. 2025, doi: 10.1016/j.shaw.2025.12.002.

[19] Syaharuddin, Fatmawati, S. A. A. Yusuf, J. Darmawan, A. Efendy, and A. Sahraini, "The Evolution of Backpropagation Neural Network Algorithms in the Development of Intelligent Flood Detection Systems," in *International Conference on Global Innovations in Education, Science, and Technology*, Sep. 2025, pp. 142–154.

[20] M. Agustini, K. Fithriasari, and D. D. Prastyo, "An Accuracy-level Method for Robust Evaluation in Predictive Analytics," *Decision Analytics Journal*, vol. 18, 2026, doi: 10.1016/j.dajour.2025.100661.
[21] S. Ma *et al.*, "Research on Fast and Accurate Prediction of Milk Yield in Dairy Goats Based on Deep Learning," *J. Dairy Sci.*, 2026, doi: 10.3168/jds.2025-27905.
[22] J. B. Deb, S. Chowdhury, and N. M. Ali, "An Investigation of The Ensemble Machine Learning Techniques for Predicting Mechanical Properties of Printed Parts in Additive Manufacturing," *Decision Analytics Journal*, vol. 12, p. 14, 2024, doi: 10.1016/j.dajour.2024.100492.
[23] H. M. Alkhezi, "A Comparative Analysis of Forecasting Models for Air Temperature: Classical Time Series, Machine Learning, and Functional Approaches," *Kuwait Journal of Science*, vol. 53, no. 1, 2026, doi: 10.1016/j.kjs.2025.100529.
[24] K. Halder *et al.*, "High-resolution Maize Yield Mapping Across Africa Using Earth Observation and Machine Learning, Deep Learning, and Foundation Model," *Science of Remote Sensing*, vol. 13, 2026, doi: 10.1016/j.srs.2025.100344.
[25] A. Kumar, "MSE vs RMSE vs MAE vs MAPE vs R-Squared: When to Use?"
[26] R. Indriyati, A. Burhanuddin, and A. Utami, "Komparasi Sarimax dan Prophet untuk Prediksi Tingkat Penghunian Kamar Hotel Jawa Tengah," *Techo.COM: Jurnal Teknologi Informasi*, vol. 23, no. 2, pp. 294–305, May 2024, Accessed: Aug. 13, 2024. [Online]. Available: https://doi.org/10.62411/tc.v23i2.8232
[27] A. Afatandio, Y. P. Purba, and M. Safii, "Backpropagation Analysis in Selecting The Best Architecture to Prediction The Number of Population of Siantar Martoba," *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, vol. 10, no. 3, pp. 567–574, Jun. 2024, doi: 10.33330/jurteksi.v10i3.2891.
[28] F. A. A. Fauzi, S. Wulandari, and D. Avianto, "Penerapan Metode Neural Network Berbasis Web Dalam Prediksi Harga Telur Ayam," *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 4, no. 6, pp. 2686–2697, Jun. 2024, doi: 10.30865/klik.v4i6.1865.
[29] M. Y. Anshori, V. Asy'Ari, T. Herlambang, and I. W. Farid, "Forecasting Occupancy Rate Using Neural Network at Hotel R," in *2023 International Conference on Advanced Mechatronics, Intelligent Manufacture and Industrial Automation (ICAMIMIA)*, IEEE, Nov. 2023, pp. 347–351. doi: 10.1109/ICAMIMIA60881.2023.10427752.
[30] Y. M. Chang, C. H. Chen, J. P. Lai, Y. L. Lin, and P. F. Pai, "Forecasting Hotel Room Occupancy Using Long Short-Term Memory Networks With Sentiment Analysis and Scores of Customer Online Reviews," *Applied Sciences*, vol. 11, no. 21, Nov. 2021, doi: 10.3390/app112110291.
[31] A. Febiola *et al.*, "Perbandingan Metode ARIMA dan SARIMA Dalam Peramalan Jumlah Penumpang Bandara Provinsi Kepulauan Bangka Belitung," *Jambura Journal of Mathematics*, vol. 6, no. 2, pp. 160–168, Aug. 2024, doi: 10.37905/jjom.v6i2.25081.
[32] R. Abubakar, *Metodologi Penelitian*. Yogyakarta: SUKA-Press UIN Sunan Kalijaga, 2021.
[33] Y. I. Mogul *et al.*, "Machine Learning-driven Backpropagation Neural Network for Robust Prediction of Surface Roughness in Ti6Al4V Abrasive Water Jet Machining With Experimental Validation," *Mater. Today Commun.*, vol. 51, 2026, doi: 10.1016/j.mtcomm.2026.114692.

[34] A. Dahiya *et al.*, "Hybrid Parking Space Prediction Model: Integrating ARIMA, Long Short-Term Memory (LSTM), and Backpropagation Neural Network (BPNN) for Smart City Development," *PeerJ Comput. Sci.*, vol. 11, 2025, doi: 10.7717/PEERJ-CS.2645.

[35] L. G. Wright *et al.*, "Deep Physical Neural Networks Trained With Backpropagation," *Nature*, vol. 601, no. 7894, pp. 549–555, Jan. 2022, doi: 10.1038/s41586-021-04223-6.

[36] B. P. Adedeji, "Prediction of Photovoltaic Power Output Using Artificial Neural Networks," *Measurement: Energy*, Feb. 2026, doi: 10.1016/j.meaene.2026.100089.

[37] Y. I. Mogul *et al.*, "Prediction of Cutting Depth in Abrasive Water Jet Machining of Ti-6AL-4V Alloy Using Back Propagation Neural Networks," *Results in Engineering*, vol. 25, Mar. 2025, doi: 10.1016/j.rineng.2025.104520.

[38] A. Momeni, B. Rahmani, M. Malléjac, P. del Hougne, and R. Fleury, "Backpropagation-free Training of Deep Physical Neural Networks," *Science (1979).*, vol. 382, no. 6676, pp. 1297–1304, Dec. 2023, doi: 10.1126/science.adi8474.

[39] A. Almomani *et al.*, "Age and Gender Classification Using Backpropagation and Bagging Algorithms," *Computers, Materials and Continua*, vol. 74, no. 2, pp. 3045–3062, 2023, doi: 10.32604/cmc.2023.030567.

[40] M. Gustineli, "A Survey on Recently Proposed Activation Functions for Deep Learning," *arXiv preprint arXiv:2204.02921*, Apr. 2022, [Online]. Available: http://arxiv.org/abs/2204.02921

[41] I. Akil, "Komparasi Fungsi Aktivasi Neural Network pada Data Time Series," *INTI Nusa Mandiri*, vol. 18, no. 1, pp. 78–83, Aug. 2023, doi: 10.33480/inti.v18i1.4288.

[42] Syaharuddin, E. Pujiana, I. P. Sari, V. M. Mardika, and M. Putri, "Analisis Algoritma Back Propagation dalam Prediksi Angka Kemiskinan di Indonesia," *Pendekar : Jurnal Pendidikan Berkarakter*, vol. 3, no. 1, pp. 11–17, Apr. 2020, doi: 10.31764.

[43] H. Mustafidah and M. Sholihah, "Tingkat Ketepatan Pengenalan Pola Data Algoritma Pelatihan pada Jaringan Syaraf Tiruan Menggunakan Model Neuron 10-16-1 dan 15-29-1," *Sainteks*, vol. 19, no. 2, p. 187, Oct. 2022, doi: 10.30595/sainteks.v19i2.15210.

[44] H. Hartono, Y. Muharni, I. Setiawan, I. Saraswati, and A. Maulana, "Load Forecasting Energi Listrik Provinsi Banten Tahun 2022-2030 Menggunakan Metode Backpropagation Neural Network," *Journal of Systems Engineering and Management*, vol. 2, no. 1, pp. 45–51, Apr. 2023, doi: 10.36055/joseam.v2i1.19265.

[45] M. Akbar, C. Guterres, and A. de Araújo, "A Backpropagation-Based Artificial Neural Network Model for Predicting Pharmaceutical Demand Timor Leste," *JURIT : Jurnal Riset Ilmu Teknik*, vol. 3, no. 1, pp. 1–15, 2025, doi: doi.org/10.59976/jurit.v1i1.155.

[46] D. Kurniasari, M. N. A. Rafdiono, and Warsono, "Analisis Struktur Terbaik Neural Network dengan Algoritma Backpropagation dalam Memprediksi Indeks Kandungan Sulfida (SO2) di Ibu Kota Jakarta," *Jurnal Sistem dan Teknologi Informasi (JUSTIN)*, vol. 12, no. 2, p. 321, Apr. 2024, doi: 10.26418/justin.v12i2.76166.

[47] W. W. Alfarisi, Z. Haura, D. A. Pratiwi, F. A. Putri, E. Sadewo, and G. Darmawan, "Comparative Analysis of Fourier Series Analysis and Holtwinters Methods on Forecasting Additive Seasonal Data," *INNOVATIVE: Journal of Social Science Research*,

vol. 4, no. 1, pp. 1310–1325, 2024, Accessed: Aug. 29, 2024. [Online]. Available: http://j-innovative.org/index.php/Innovative/article/view/7570