

Prediksi Jumlah Kedatangan Pasien Puskesmas Menggunakan Metode Backpropagation Artificial Neural Network

Sandi Satria Alamsyah, Maimunah, Pristi Sukmasetya*

Fakultas Teknik, Informatika, Universitas Muhammadiyah Magelang, Magelang, Indonesia
Email: ¹sandisatriaalamsyah@gmail.com, ²maimunah@ummgl.ac.id, ^{3,*}pristi.sukmasetya@ummgl.ac.id
Email Penulis Korespondensi: pristi.sukmasetya@ummgl.ac.id

Abstrak—Prediksi jumlah kunjungan pasien merupakan salah satu aspek penting dalam manajemen puskesmas untuk mengoptimalkan alokasi sumber daya yang tersedia. Namun, pola kunjungan pasien yang tidak menentu seringkali menyulitkan proses perencanaan dan pengambilan keputusan. Penelitian ini bertujuan untuk mengembangkan model prediksi kunjungan pasien di puskesmas Grabag 1 menggunakan metode Backpropagation Artificial Neural Network. Backpropagation adalah sebuah teknik algoritma pembelajaran yang digunakan dalam model jaringan saraf tiruan dengan beberapa lapisan tersembunyi. Dalam penelitian ini terdapat beberapa tahapan pemrosesan data, yaitu memilih atribut data yang digunakan, mengatasi *missing value*, normalisasi data, *sliding window*, dan pembagian data *training* dan *testing*. Prediksi ini dapat digunakan oleh pihak puskesmas untuk merencanakan kebutuhan sumber daya secara lebih efisien, seperti penjadwalan tenaga medis, persediaan obat-obatan, dan pengelolaan fasilitas penunjang lainnya. Data yang digunakan penelitian ini merupakan data *time series* yang berasal dari rentang tahun 2019 hingga 2023 sebanyak 1826 data. Setelah melakukan berbagai percobaan, hasil terbaik diperoleh dengan menggunakan kombinasi nilai epoch sebesar 500, jumlah *neuron* pada lapisan *input* sebanyak 30, jumlah lapisan tersembunyi (*hidden layer*) sebanyak 1, jumlah *hidden neuron* sebanyak 7, dan jumlah *input* pada lapisan *output* sebanyak 1. Konfigurasi arsitektur jaringan saraf tiruan ini mampu menghasilkan nilai kesalahan kuadrat rata-rata (*Mean Squared Error*/MSE) sebesar 0,00229501 untuk data pelatihan dan 0,00782101 untuk data pengujian.

Kata Kunci: Prediksi; Pasien; Puskesmas; Backpropagation; Data Mining

Abstract—Patient visit prediction is a crucial aspect of community health center management to optimize the allocation of available resources. However, the erratic pattern of patient visits often complicates the planning and decision-making processes. This research aims to develop a patient visit prediction model for Grabag 1 Community Health Center using the backpropagation artificial neural network method. Backpropagation is a learning algorithm technique used in artificial neural network models with multiple hidden layers. In this research, there are several stages of data processing, including selecting the data attributes used, handling missing values, data normalization, sliding window, and dividing the data into training and testing sets. This prediction can be utilized by the health center to efficiently plan resource requirements, such as scheduling medical staff, managing medication supplies, and maintaining supporting facilities. The data used in this research is a time series spanning from 2019 to 2023. After conducting various experiments, the best results were obtained using a combination of 500 epochs, 30 input neurons, 1 hidden layer, 7 hidden neurons, and 1 output neuron. This artificial neural network architecture configuration achieved a Mean Squared Error (MSE) of 0.00229501 for the training data and 0.00782101 for the testing data.

Keywords: Predict; Patient; Public health center; Backpropagation; Data Mining

1. PENDAHULUAN

Puskesmas merupakan fasilitas atau tempat yang menyediakan layanan terkait kesehatan untuk masyarakat yang dibiayai oleh pemerintah. Institusi ini berfungsi sebagai tempat rujukan bagi masyarakat untuk melakukan pemeriksaan dan konsultasi terkait masalah kesehatan. Dengan kata lain, puskesmas merupakan pusat layanan kesehatan yang didanai oleh pemerintah dan menjadi tempat utama bagi masyarakat untuk memperoleh pelayanan dan konsultasi kesehatan secara langsung [1]. Seiring dengan pertumbuhan populasi manusia dan perkembangan perekonomian, kesadaran masyarakat tentang kesehatan juga semakin meningkat. Kondisi ini berdampak pada peningkatan jumlah pasien yang berkunjung ke berbagai layanan kesehatan [2]. Peningkatan jumlah pasien yang datang ke puskesmas sering kali diartikan sebagai indikator keberhasilan dalam meningkatkan aksesibilitas pelayanan kesehatan. Namun, di sisi lain, hal ini juga bisa menyebabkan tantangan tersendiri, terutama terkait kapasitas pelayanan dan manajemen sumber daya. Informasi mengenai jumlah pasien yang berkunjung merupakan hal yang sangat penting bagi manajemen operasional layanan kesehatan. Peningkatan atau penurunan jumlah pasien akan berdampak pada operasional dan layanan yang diberikan. Setidaknya terdapat tiga aspek pelayanan yang sangat dipengaruhi oleh jumlah pasien, yaitu ketersediaan obat-obatan dan perlengkapan medis, pengelolaan sumber daya tenaga medis seperti dokter, perawat, dan staf administrasi, serta kapasitas ruang rawat inap. Selain itu, jumlah pasien juga mempengaruhi aspek lain seperti area parkir, kapasitas lobi, waktu tunggu antrian, serta fasilitas pendukung seperti kantin dan toilet [3].

Puskesmas Grabag 1 merupakan salah satu layanan kesehatan yang berlokasi di Jalan Telaga Bleder, Kecamatan Grabag, Kabupaten Magelang. Setiap hari, fasilitas kesehatan masyarakat ini menerima kunjungan pasien untuk mengatasi permasalahan kesehatan mereka, baik dari kalangan atas maupun kalangan bawah. Lonjakan jumlah pengunjung yang tidak menentu di Puskesmas Grabag 1 mengakibatkan kurangnya pelayanan secara optimal. Pada hari-hari tertentu, terjadi antrian panjang pasien yang tidak diiringi dengan penambahan jumlah tenaga medis dan administrasi untuk mengimbangi tingginya kunjungan pasien. Dalam mengatasi permasalahan tersebut, penulis memanfaatkan data mining untuk memperkirakan atau memproyeksikan banyaknya pasien yang akan berkunjung dan membutuhkan layanan di waktu atau periode mendatang. Data mining merupakan proses penganalisaan dan eksplorasi sekumpulan data secara komprehensif untuk mengungkap pola, tren, atau hubungan yang sebelumnya tidak teridentifikasi, serta melakukan

peringkasan atau representasi data dalam bentuk yang dapat memberikan wawasan dan nilai tambah bagi pemilik data [4]. Memprediksi atau memperkirakan kejadian mendatang berdasarkan data masa lalu merupakan hal yang sangat penting. Alasannya, prediksi terhadap peristiwa di masa depan memberikan masukan yang berharga dalam berbagai perencanaan dan proses pengambilan keputusan. Sebagai ilustrasi, dalam pengelolaan operasional, perusahaan bisnis secara rutin menggunakan perkiraan penjualan produk atau permintaan konsumen untuk menyusun jadwal produksi, mengelola rantai pasokan, dan mengontrol persediaan barang [5]. Pada penelitian ini, penerapan data mining dilakukan dengan membangun model prediksi menggunakan metode Artificial Neural Network. Artificial Neural Network merupakan jaringan saraf tiruan yang digunakan dalam melakukan prediksi dengan kemampuannya dalam melakukan pembelajaran mandiri dari data latih yang telah diberikan [6].


Penelitian tentang prediksi kunjungan pasien di puskesmas yang dilakukan di puskesmas Haekesak yang berada di kabupaten Belu Provinsi Nusa Tenggara Timur, dari penelitian ini menghasilkan jumlah kunjungan pasien pada periode hari ke-26 hingga ke-35 cenderung stabil, tanpa peningkatan atau penurunan yang berarti [7]. Beberapa penelitian telah dilakukan untuk memprediksi data *time series*, diantaranya yaitu penelitian yang dilakukan untuk memprediksi jumlah sampah yang dihasilkan di TPSA dengan metode Backpropagation Artificial Neural Network. Penelitian tersebut menghasilkan tingkat akurasi MSE terbaik dengan nilai 0.018870 dengan menggunakan parameter terbaik berupa jumlah *input layer* 30, sementara *hidden layer* berjumlah 1 dengan *hidden neuron* sejumlah 7 dan 1 *output layer* dengan epoch sebesar 1000 [8]. Adapun penelitian lain yang menggunakan Menggunakan Artificial Neural Network Algoritma Backpropagation untuk memprediksi produksi padi yang berhasil mencapai akurasi sebesar 88,14%. Namun, proses trial dan *error* perlu dilakukan secara intensif untuk mendapatkan hasil yang lebih maksimal dalam waktu yang lebih singkat. Aplikasi prediksi produksi padi ini mampu memprediksi produksi padi tahun 2018 setelah melakukan 75 kali pengujian terhadap parameter-parameter dalam model prediksi. Hasil pengujian tersebut menghasilkan model dengan konfigurasi optimal, yaitu terdiri dari 3 neuron pada *input layer*, 3 *hidden layer*, 1 lapisan *output*, epoch 200, momentum 0,5, dan *learning rate* 0,5 [9].

Penelitian lain dilakukan dalam memprediksi penyakit diabetes menggunakan metode Artificial Neural Network. Penelitian tersebut menghasilkan model akurasi tertinggi sebesar 88%. Untuk meningkatkan performa model di masa mendatang, diharapkan jumlah data yang digunakan dalam pelatihan dapat ditambah. Hal ini bertujuan agar model yang dihasilkan mampu mencapai tingkat akurasi yang lebih tinggi dibandingkan penelitian sebelumnya [10]. Penelitian lain tentang penggunaan metode deep learning telah dilakukan untuk memprediksi kesuksesan *start-up*. Penelitian menghasilkan Model prediksi yang dibangun tidak mengalami underfitting maupun *overfitting*, sehingga dapat diandalkan untuk memprediksi kesuksesan sebuah startup. Model ini memiliki akurasi sebesar 89,29%, presisi sebesar 90,20%, dan tingkat kesalahan sebesar 10,71% [11]. Penelitian lain yang menggunakan Artificial Neural Network tentang memprediksi gagal jantung yang menghasilkan akurasi sebesar 92,032% dan AUC sebesar 93% dengan menggunakan 2 *hidden layer*, 15 jumlah *neuron* untuk *hidden layer* pertama dan 10 buah untuk *hidden layer* kedua [12].

Tujuan dari penelitian ini adalah untuk meramalkan banyaknya pasien yang berkunjung ke puskesmas Grabag 1 menggunakan metode Backpropagation Artificial Neural Network. Harapannya, hasil penelitian dapat mempermudah pihak puskesmas dalam mengatur sumber daya mereka secara lebih efektif dan ekonomis, sehingga pada akhirnya mampu memperbaiki kualitas pelayanan kesehatan untuk semua pasien.

2. METODOLOGI PENELITIAN

Berikut gambar 1 merupakan tahapan dari proses penelitian yang dilakukan.



Gambar 1. Rangkaian Proses Penelitian

Gambar 1 menyajikan rangkaian proses yang dilakukan dalam penelitian ini yang ditampilkan secara visual dalam sebuah bagan atau diagram yang merepresentasikan kerangka kerja penelitian yang digunakan. Alur penelitian tersebut menyajikan proses prediksi menggunakan algoritma Artificial Neural Network. Alur penelitian dimulai dengan pengumpulan data yang diperlukan dari sumber Puskesmas Grabag 1. Selanjutnya, data tersebut diolah melalui tahap pre-processing untuk menangani data yang hilang, melakukan normalisasi, dan transformasi data. Setelah data siap, proses prediksi dilakukan dengan melatih model menggunakan metode Backpropagation Artificial Neural Network dan kemudian digunakan untuk memprediksi jumlah kedatangan pasien di masa yang akan datang. Tahap terakhir yaitu menguji akurasi model dengan membandingkan data aktual dan data prediksi menggunakan metrik evaluasi seperti akurasi, presisi, atau recall untuk memastikan performa model yang baik dan dapat diandalkan.

2.1 Pengumpulan Data

Dalam tahapan ini, dilakukan pengumpulan data dari Puskesmas Grabag 1 yang berupa data kunjungan pasien selama periode waktu antara tahun 2019 hingga 2023 dengan jumlah 1826 data. Data yang terkumpul ini merupakan jenis data *time series*. *Time series* adalah kumpulan data observasi yang tersusun secara berurutan berdasarkan waktu. Analisis *time*

series merupakan metode peramalan kuantitatif yang bertujuan untuk mengidentifikasi pola data dari masa lalu yang dikumpulkan menurut urutan waktu [13].

2.2 Pre-processing Data

Pre-processing merupakan tahapan praprocess yang melibatkan persiapan dan pengolahan awal terhadap data yang telah diperoleh, dengan tujuan agar data tersebut berada dalam kondisi yang siap untuk diproses lebih lanjut saat dilakukan pembuatan model (pemodelan) [14]. Dalam penelitian ini terdapat beberapa tahapan pemrosesan data, yaitu memilih atribut data yang digunakan, mengatasi *missing value*, normalisasi data, *sliding window*, dan pembagian data *training* dan *testing*. *Missing value* merupakan situasi di mana terdapat nilai-nilai yang hilang, tidak utuh, atau kosong pada satu atau lebih variabel atau fitur dalam sebuah dataset [15]. Keberadaan nilai-nilai yang hilang atau tidak lengkap dalam suatu set data merupakan fenomena yang lazim terjadi yang disebabkan oleh berbagai faktor seperti kegagalan atau kerusakan peralatan, ketidakakuratan dalam proses pengumpulan data, kelalaian dalam pencatatan data, serta permasalahan teknis lainnya [16]. Pada penelitian ini, penanganan *missing value* dilakukan dengan imputasi nilai kosong menggunakan nilai median. Penerapan metode imputasi *median* yang dipadukan dengan penanganan data outlier menggunakan pendekatan *median* dan algoritma klasifikasi tertentu terbukti dapat meningkatkan kinerja sistem secara keseluruhan. Kombinasi teknik ini mampu mengatasi permasalahan *missing values* dan data ekstrim, sehingga menghasilkan peningkatan performa dalam memprediksi atau mengklasifikasikan data [17]. Setelah mengatasi *missing value*, tahap selanjutnya adalah normalisasi data dengan mentransformasi nilai-nilai pada fitur/variabel yang ada sehingga memiliki jangkauan atau rentang nilai yang seragam atau setara [18]. Normalisasi data pada penelitian ini dilakukan dengan menggunakan MinMaxScaler dengan rentang nilai 0 dan 1. Tahap berikutnya yaitu teknik *sliding window* yang dilakukan dengan *window size* sebesar 30. *Sliding window* atau metode *windowing* merupakan sebuah cara untuk mengonversi data deret waktu (*time series*) menjadi data dalam format *cross-sectional*. Proses ini melibatkan pembentukan struktur baru dari data *time series* dengan memotong atau mengambil sejumlah nilai observasi dalam jendela *window* tertentu sepanjang deretan waktu [19].

2.3 Prediksi Kedatangan Pasien

Prediksi yang dilakukan pada penelitian ini menggunakan metode Backpropagation Artificial Neural Network. Pemodelan prediksi pada penelitian ini dilakukan dengan mengkombinasikan beberapa parameter pada metode Backpropagation Artificial Neural Network untuk mendapatkan parameter dengan akurasi terbaik dalam memprediksi jumlah kedatangan pasien. Parameter yang digunakan disajikan pada Tabel 1.

Tabel 1. Parameter yang Digunakan

Parameter	
Lapisan <i>Input</i>	30
Lapisan Tersembunyi	1
<i>Neuron</i> Tersembunyi	5, 7, 10, 14
Lapisan <i>Output</i>	1
Epoch	150, 250, 350, 500
<i>Learning Rate</i>	0,01

Tabel 1 memvisualisasikan kombinasi nilai-nilai parameter yang akan diuji berupa lapisan *input*, *neuron* tersembunyi, epoch, lapisan *output*. Kombinasi parameter 150, 250, 350, dan 500 dipilih dalam penelitian ini mengingat pendekatan serupa dengan menggabungkan parameter-parameter tersebut telah banyak digunakan dan terbukti efektif dalam sejumlah studi sebelumnya.

2.3.1 Backpropagation Artificial Neural Network

Neural Network merupakan teknik pembelajaran mesin populer yang mensimulasikan mekanisme pembelajaran pada organisme biologis. Mekanisme biologis ini disimulasikan dalam jaringan saraf tiruan yang berisi saraf komputasi yang disebut neuron [20]. Backpropagation adalah sebuah teknik algoritma pembelajaran yang digunakan dalam model jaringan saraf tiruan dengan beberapa lapisan tersembunyi. Algoritma ini memungkinkan penyesuaian bobot-bobot koneksi antara neuron-neuron pada lapisan tersembunyi secara iteratif berdasarkan data pelatihan yang diberikan. Tujuannya adalah untuk meminimalkan kesalahan antara keluaran yang dihasilkan oleh model dengan target yang diharapkan, sehingga kinerja model dapat ditingkatkan secara bertahap melalui proses *supervised learning* [21].

Proses pelatihan pada algoritma backpropagation melibatkan serangkaian tahapan atau langkah-langkah yang perlu dilakukan secara berurutan. Berikut ini adalah rangkaian proses atau tahapan yang harus dilakukan untuk melakukan pelatihan pada algoritma Backpropagation [22]:

- a. *feed-forward* merupakan tahapan di mana sinyal masukan diteruskan dari lapisan *input* menuju lapisan tersembunyi..
 1. Pada setiap lapisan *input*, terdapat sejumlah *neuron* (X_i , dengan $i = 1, 2, 3, \dots, n$) yang menerima nilai *input* tertentu. Nilai masukan tersebut kemudian diteruskan oleh masing-masing neuron pada lapisan *input* ke setiap *neuron* pada lapisan tersembunyi yang terhubung dengannya.

2. Pada setiap *neuron* di lapisan tersembunyi yang dilambangkan dengan Z_j , dengan $j = 1, 2, 3, \dots, p$, terjadi proses penjumlahan terbobot dari sinyal-sinyal masukan yang diterima. Nilai-nilai bobot pada koneksi masukan tersebut dijumlahkan, kemudian ditambahkan dengan sebuah nilai bias.

$$Z_{inj} = V_0j + \sum_{i=1}^n X_i V_{ij} \quad (1)$$

3. Setelah melakukan penjumlahan terbobot dari sinyal masukan dan menambahkannya dengan bias pada setiap *neuron* di lapisan tersembunyi, nilai hasil penjumlahan tersebut Z_{inj} selanjutnya dikalikan dengan suatu fungsi aktivasi tertentu.

$$Z_j = f(Z_{inj}) = \frac{1}{1 + e^{-Z_{inj}}} \quad (2)$$

- b. Setelah melakukan tahap *feed-forward*, dilanjutkan dengan tahap *backpropagation*

1. Pada setiap *neuron* di lapisan output (Y_k), nilai keluaran dihitung berdasarkan pola masukan dari data pelatihan. Selanjutnya, dilakukan perhitungan nilai kesalahan antara keluaran yang dihasilkan oleh *neuron-neuron* pada lapisan *output* dengan target keluaran yang diharapkan untuk pola masukan tersebut.

$$\delta_k = (t_k - Y_k) f'(Y_k) \quad (5)$$

$$\delta_k = (t_k - Y_k) Y_k (1 - Y_k) \quad (6)$$

2. Berdasarkan nilai kesalahan yang diperoleh pada lapisan *output*, dilakukan perhitungan untuk mengoreksi atau menyesuaikan nilai bobot (W_{jk}) pada koneksi antara lapisan tersembunyi dan lapisan output.

$$\Delta W_{jk} = \alpha \cdot \delta_k Z_j \quad (7)$$

3. Langkah selanjutnya adalah menghitung nilai kesalahan pada setiap *neuron* di lapisan tersembunyi yang dilambangkan dengan δ_{in_j} .

$$\delta_{in_j} = \sum_{k=1}^m \delta_k W_{jk} \quad (8)$$

4. Nilai kesalahan (δ_{in_j}) yang diperoleh pada setiap *neuron* di lapisan tersembunyi selanjutnya dikalikan dengan turunan dari fungsi aktivasi yang digunakan pada *neuron* tersebut terhadap nilai masukan yang diterima.

$$\delta_j = \delta_{in_j} f'(Z_{inj}) \quad (9)$$

$$\delta_j = (\delta_{in_j}) Z_j (1 - Z_j) \quad (10)$$

5. Berdasarkan nilai kesalahan akhir (δ_j) yang telah dihitung pada setiap *neuron* di lapisan tersembunyi, dilakukan perhitungan untuk mengoreksi atau menyesuaikan nilai bobot (V_{ij}) pada koneksi antara lapisan masukan dan lapisan tersembunyi.

$$\Delta V_{ij} = \alpha \cdot \delta_j X_i \quad (11)$$

- c. Setelah mendapatkan nilai koreksi bobot baik untuk koneksi antara lapisan tersembunyi dan lapisan *output* (ΔW_{jk}) maupun koneksi antara lapisan *input* dan lapisan tersembunyi (ΔV_{ij}), dilakukan proses penyesuaian atau pembaharuan nilai bobot-bobot tersebut dengan menambahkan nilai koreksi bobot yang telah dihitung.

1. Pada setiap *neuron* di lapisan *output* (Y_k), proses penyesuaian tidak hanya melibatkan pembaharuan nilai bobot pada koneksi dari lapisan tersembunyi, tetapi juga meliputi pembaharuan nilai bias (θ_k) yang terkait dengan *neuron* tersebut. Nilai bias dikoreksi dengan menambahkan suatu nilai tertentu yang dihitung berdasarkan kesalahan pada lapisan *output*.

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{jk} \quad (12)$$

2. Pada setiap *neuron* di lapisan tersembunyi (Z_j), proses penyesuaian meliputi pembaharuan nilai bobot pada koneksi dari lapisan *input* serta pembaharuan nilai bias (θ_j) yang terkait dengan *neuron* tersebut. Nilai bias pada lapisan tersembunyi dikoreksi dengan menambahkan suatu nilai koreksi yang dihitung berdasarkan kesalahan pada lapisan tersembunyi.

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (13)$$

2.4 Analisis Tingkat Kesalahan

Mean Squared Error (MSE) adalah suatu metrik yang mengukur rata-rata dari kuadrat selisih antara nilai-nilai keluaran yang dihasilkan oleh model dengan nilai-nilai target atau nilai sebenarnya yang diharapkan. Dengan kata lain, MSE menghitung rata-rata dari kuadrat perbedaan antara prediksi model dan observasi actual [23]. Untuk menghitung nilai *Mean Squared Error* (MSE), rumus yang digunakan adalah:

$$MSE = \frac{\sum(\text{kesalahan peramalan})^2}{n} \quad (14)$$

2.5 Hasil Prediksi Kedatangan Pasien

Hasil yang diperoleh dari proses prediksi adalah perkiraan jumlah pasien yang akan datang berkunjung ke puskesmas Grabag 1 untuk rentang waktu 30 hari ke depan. Prediksi jumlah kunjungan pasien ini akan disajikan dalam bentuk tabel guna memudahkan interpretasi dan pemahaman terhadap hasil prediksi. Visualisasi tabel tersebut akan menunjukkan pola fluktuasi jumlah pasien, baik kenaikan maupun penurunan pada periode waktu tertentu di masa mendatang.

3. HASIL DAN PEMBAHASAN

Dalam penelitian ini, metode Backpropagation Artificial Neural Network (ANN) digunakan untuk memprediksi jumlah kedatangan pasien di puskesmas. Hasil penelitian menunjukkan bahwa metode Backpropagation ANN mampu memprediksi jumlah kedatangan pasien dengan akurasi yang baik. Selain itu, ditemukan bahwa jumlah *neuron* pada lapisan tersembunyi dan fungsi aktivasi yang digunakan berpengaruh signifikan terhadap kinerja model. Pemilihan parameter yang tepat, seperti *learning rate* dan momentum, juga berkontribusi pada keberhasilan prediksi menggunakan metode ini.

3.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini berupa data jumlah kedatangan pasien di Puskesmas Grabag 1 selama rentang waktu dari Januari 2019 hingga Desember 2023 yang berjumlah 1826 data. Representasi visual dari sebagian data yang dimanfaatkan dalam penelitian ini ditampilkan dalam bentuk Tabel 2.

Tabel 2. Data Pasien Puskesmas Grabag 1

No	Tanggal	Jumlah Pasien
1	1 Januari 2019	1
2	2 Januari 2019	207
3	3 Januari 2019	156
4	4 Januari 2019	88
5	5 Januari 2019	117
6	6 Januari 2019	208
...		
1826	28 Desember 2023	177
1827	29 Desember 2023	188
1828	30 Desember 2023	189

Tabel 2 menyajikan data yang akan diolah untuk memprediksi jumlah kedatangan pasien harian untuk periode kedepan. Data yang digunakan berupa data dengan format excel yang terdiri dari beberapa atribut berupa Nomor, Tanggal, dan Jumlah Pasien.

3.2 Pre-processing Data

Setelah pengumpulan data, tahapan yang dilakukan selanjutnya adalah melakukan pemrosesan data. Proses awal yang dilakukan dalam pengolahan data awal (*pre-processing*) adalah melengkapi nilai-nilai yang hilang atau tidak ada pada data dengan memasukkan nilai tengah (median) dari keseluruhan data. Setelah mengatasi *missing value*, dilakukan tahapan normalisasi data. Data yang digunakan pada penelitian ini memiliki rentang nilai yang jauh antara nilai minimum dan nilai maksimum pada jumlah pasien harian. Untuk mengatasi rentang data yang jauh maka dilakukan tahapan normalisasi pada preprocessing data. Normalisasi yang dilakukan pada penelitian ini menggunakan metode *min-max normalization* untuk memperkecil rentang data jumlah kedatangan pengunjung. Pada *pre-processing* data juga dilakukan *sliding window* dengan *window size* sebesar 30. *Sliding window* diterapkan dengan tujuan untuk mendapatkan kombinasi jumlah variabel *input* yang optimal, sehingga dapat digunakan untuk melatih model prediksi agar mencapai performa terbaik. Setelah tahap normalisasi data, tahapan *pre-processing* selanjutnya berupa pembagian data menjadi dua kelompok terpisah, yaitu data *train* dan data *test*. Pembagian data dilakukan dengan tujuan untuk melatih model serta mengukur tingkat kesalahan dari model yang dibangun. Dalam penelitian ini, pembagian data dilakukan dengan memisahkan 1826 data menjadi 2 bagian, dengan 80% sebagai data *train* sejumlah 1460 data dan 20% sebagai data *test* dengan jumlah 366 data. Pemisahan data menjadi data *train* dan data *test* dilakukan dengan mengadopsi pendekatan yang sebelumnya telah memberikan hasil dengan akurasi yang baik dalam studi kasus terkait.

3.3 Prediksi Kedatangan Pasien

Setelah tahap pre-processing data, tahapan yang dilakukan selanjutnya yaitu proses prediksi menggunakan Backpropagation Neural Network dengan mengkombinasikan beberapa parameter untuk mendapatkan hasil prediksi dengan akurasi yang terbaik. Hasil eksperimen dari beberapa kombinasi parameter yang telah dilakukan dengan

mengkombinasikan parameter jumlah *neuron* tersembunyi (*hidden neuron*) dan jumlah iterasi pembelajaran (*epoch*) yang digunakan disajikan pada Tabel 3.

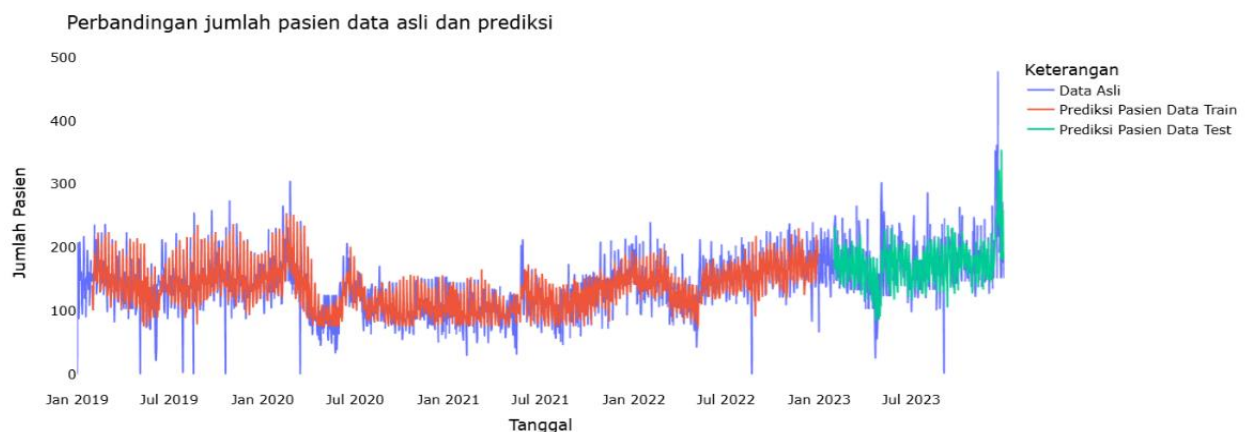
Tabel 3. Hasil yang Didapatkan Dari Parameter yang Digunakan

Epoch	Neuron Tersembunyi	Nilai MSE- <i>train</i>	Nilai MSE- <i>test</i>
150	5	0.00262922	0.007361131
	7	0.00258854	0.007774769
	10	0.00262377	0.007337253
	14	0.00237459	0.007646935
250	5	0.00238735	0.00747730
	7	0.00261651	0.00794788
	10	0.00236712	0.00799693
	14	0.00235789	0.00776986
350	5	0.00244121	0.00807774
	7	0.00243592	0.00771049
	10	0.00236327	0.00772975
	14	0.00300211	0.00883055
500	5	0.00303882	0.00864987
	7	0.00229501	0.00782101
	10	0.00236594	0.00785708
	14	0.00243283	0.00808671

Berdasarkan hasil eksperimen yang disajikan Tabel 3, masing-masing eksperimen dengan berbagai arsitektur menghasilkan nilai akurasi yang berbeda-beda. Pada *epoch* dengan nilai 150, arsitektur terbaik didapatkan dengan nilai *neuron* tersembunyi sebesar 14. Model dengan arsitektur tersebut menghasilkan nilai akurasi MSE pada data *train* sebesar 0.00237459 dan data *test* sebesar 0.007646935. Arsitektur dengan *epoch* 250 didapatkan akurasi terbaik dengan kombinasi *neuron* tersembunyi sebesar 14 dengan nilai MSE-*train* adalah 0.00235789 dan MSE *test* sebesar 0.00776986. Sementara arsitektur dengan *epoch* 350 menghasilkan nilai MSE terbaik pada kombinasi *neuron* tersembunyi sebesar 10. Arsitektur tersebut menghasilkan MSE *train* sebesar 0.00236327 dan MSE *test* sebesar 0.00772975. Pada pengujian parameter dengan struktur *epoch* 500 menghasilkan akurasi terbaik pada parameter dengan nilai *neuron* tersembunyi sebesar 7. Kombinasi parameter tersebut menghasilkan model dengan nilai MSE *train* sebesar 0.00229501 dan MSE *test* sebesar 0.00782101. Sementara arsitektur dengan *epoch* 500 menghasilkan arsitektur terbaik dengan kombinasi *neuron* tersembunyi sebesar 7 dengan nilai MSE *train* 0.00229501 dan MSE *test* 0.00782101.

3.4 Analisis Tingkat Kesalahan

Model yang optimal adalah model yang menghasilkan nilai kesalahan kuadrat rata-rata yang paling rendah. Kinerja pada model Backpropagation Neural Network dalam memprediksi jumlah kedatangan pasien di Puskesmas Grabag 1 didapatkan nilai MSE yang berbeda dari masing-masing kombinasi *epoch* dan *neuron* tersembunyi. Berdasarkan hasil pengujian, arsitektur terbaik didapatkan dengan nilai *epoch* sebesar 500 dengan arsitektur 30 *neuron input*, 7 *neuron* tersembunyi, dan 1 *neuron output*. Grafik pada Gambar 2 menyajikan visualisasi perbandingan antara data aktual jumlah pasien di puskesmas Grabag 1 dan hasil prediksi kedatangan pasien di puskesmas Grabag 1. Data tersebut memvisualisasikan perbandingan data dalam rentang waktu 1 Januari 2019 hingga 31 Desember 2023.



Gambar 2. Gambar grafik perbandingan jumlah pasien data asli dan prediksi

Gambar 2 memvisualisasikan perbandingan antara data sebenarnya (aktual) dengan data hasil prediksi yang dihasilkan oleh model dengan konfigurasi arsitektur terbaik. Dari berbagai skenario pengaturan parameter yang telah diuji coba, hasil terbaik menunjukkan korelasi yang cukup baik antara grafik data aktual dan data prediksi, di mana garis pada grafik prediksi hampir menyerupai pola garis pada grafik data aktual. Model mampu memberikan prediksi yang baik antara data aktual dan data prediksi dengan nilai MSE yang baik yaitu MSE pada data *train* sebesar 0.00229501 dan MSE pada data *test* sebesar 0.00782101

3.5 Hasil Prediksi Kedatangan Pasien

Dalam upaya meningkatkan efisiensi layanan kesehatan di puskesmas Grabag 1, penelitian ini dilakukan dengan tujuan untuk memperkirakan banyaknya kunjungan pasien dengan mengimplementasikan algoritma Backpropagation Artificial Neural Network. Studi ini hanya memanfaatkan data jumlah kunjungan pasien yang terakumulasi per bulan sebagai bahan analisis. Dengan pendekatan ini, diharapkan dapat diperoleh prediksi yang akurat untuk mengoptimalkan alokasi sumber daya dan meningkatkan kualitas pelayanan kesehatan di fasilitas tersebut. Tabel 4 menyajikan prediksi jumlah pasien yang mengunjungi puskesmas Grabag 1 dalam jangka 30 hari kedepan.

Tabel 4 Hasil yang didapatkan dari Parameter yang digunakan

Tanggal	Hasil Prediksi (pasien)
1 Januari 2024	220
2 Januari 2024	219
3 Januari 2024	274
....	...
14 Januari 2024	141
15 Januari 2024	255
16 Januari 2024	202
17 Januari 2024	265
...	...
28 Januari 2024	164
29 Januari 2024	212
30 Januari 2024	193

Hasil prediksi jumlah kunjungan pasien untuk periode 30 hari ke depan yang ditunjukkan pada Tabel 4 mengindikasikan adanya fluktuasi jumlah pasien, baik kenaikan maupun penurunan di hari-hari tertentu. Berdasarkan prediksi tersebut, puncak jumlah kunjungan pasien pada bulan Januari 2024 diproyeksikan terjadi pada tanggal 3 Januari dengan total 274 orang pasien. Sementara itu, jumlah kunjungan pasien terendah pada bulan yang sama diprediksi akan terjadi pada tanggal 14 Januari dengan hanya 141 orang pasien yang akan berkunjung pada hari tersebut.

4 KESIMPULAN

Hasil penelitian menunjukkan bahwa model prediksi kunjungan pasien menggunakan metode Backpropagation Artificial Neural Network yang diusulkan mampu memberikan perkiraan jumlah kunjungan pasien dengan akurasi yang cukup baik. Dari beberapa percobaan parameter yang telah dilakukan, arsitektur dengan epoch 150 didapatkan model terbaik dengan kombinasi parameter nilai *input layer* sebesar 30, *hidden layer* sebesar 1, *hidden neuron* sebesar 14, lapisan *output* dengan nilai 1. Percobaan lain dengan nilai epoch sebesar 250 menghasilkan model terbaik dengan kombinasi parameter *input layer* adalah 30, *hidden layer* sebesar 1, *hidden neuron* dengan nilai 14, lapisan *output* sebesar 1. Pada epoch 350 model menghasilkan nilai MSE terendah pada model dengan parameter *input layer* sebesar 30, *hidden layer* adalah 1, *hidden neuron* sebesar 10. Dari percobaan yang telah dilakukan, model Backpropagation Neural Network menghasilkan akurasi terbaik dalam memprediksi jumlah kunjungan pasien di puskesmas menggunakan arsitektur model dengan nilai epoch sebesar 500 dan *input layer* sebesar 30, *hidden layer* dengan nilai 1, *hidden neuron* sebesar 7, lapisan *output* adalah 1 dengan hasil MSE *train* 0.00229501 dan MSE *test* 0.00782101. Berdasarkan percobaan yang telah dilakukan, model dengan hasil prediksi terbaik didapatkan dari kombinasi nilai epoch 500 dan *hidden neuron* sebesar 7. Dari hasil prediksi yang telah dilakukan, terdapat kenaikan dan penurunan terhadap jumlah pasien di puskesmas Grabag 1 selama periode 30 hari kedepan. Penelitian terkait prediksi jumlah kedatangan pasien menggunakan metode Backpropagation Artificial Neural Network masih memerlukan pengembangan lebih lanjut. Studi berikutnya dapat meneruskan penelitian ini dengan membangun model baru menggunakan berbagai kombinasi parameter dan memanfaatkan dataset dari sumber-sumber yang beragam serta jenis variabel yang bervariasi. Tujuannya adalah untuk memperoleh hasil prediksi yang lebih akurat dan optimal dibandingkan dengan penelitian saat ini. Dengan meningkatkan jumlah dan keragaman sumber data serta variabel yang digunakan, diharapkan model prediksi yang dihasilkan dapat memberikan estimasi jumlah kedatangan pasien di puskesmas dengan tingkat kesalahan (*error*) yang lebih rendah.

REFERENCES

- [1] A. E. Syaputra and Y. S. Eirlangga, "Prediksi Tingkat Kunjungan Pasien dengan Menggunakan Metode Monte Carlo," *J. Inf.*

- dan Teknol., vol. 4, no. 2, pp. 97–102, 2022, doi: 10.37034/jidt.v4i2.202.
- [2] W. M. Baihaqi, M. Dianingrum, and K. aswin N. Ramadhan, “Regresi linier sederhana untuk memprediksi kunjungan pasien di rumah sakit berdasarkan jenis layanan dan umur pasien,” *J. Simetris*, vol. 10, no. 2, pp. 671–680, 2019.
- [3] A. Wibowo, D. Iskandar, and W. A. S. Wibowo, “Data Mining Dalam Prediksi Jumlah Pasien Dengan Regresi Linear Dan Exponential Smoothing,” *J. Sist. Inf. dan Sains Teknol.*, vol. 5, no. 1, pp. 1–8, 2023.
- [4] D. P. Utomo and M. Mesran, “Analisis Komparasi Metode Klasifikasi Data Mining dan Reduksi Atribut Pada Data Set Penyakit Jantung,” *J. Media Inform. Budidarma*, vol. 4, no. 2, p. 437, 2020, doi: 10.30865/mib.v4i2.2080.
- [5] V. A. Lestari, A. Y. Ananta, and P. Basudewa, “Sistem Informasi Prediksi Persediaan Obat Di Apotek Naylun Farma Menggunakan Holt-Winters,” *J. Inform. Polinema*, vol. 9, no. 2, pp. 229–236, 2023, doi: 10.33795/jip.v9i2.1289.
- [6] H. Pratiwi, *Kecerdasan Buatan: Disertai Praktik Baik Pemanfaatannya*. Samarinda: Asadel Liamsindo Teknologi, 2024.
- [7] N. E. De Jesusi and fauzan anief Rozi, “Penerapan Data Mning Untuk Memprediksi Jumlah Data Pasien Di Puskesmas Haekesak Menggunakan Metode Arima,” *Bussiness Law binus*, vol. 7, no. 2, pp. 33–48, 2020.
- [8] W. Santoso, Maimunah, and P. Sukmasetya, “JURNAL MEDIA INFORMATIKA BUDIDARMA Prediksi Volume Sampah di TPSA Banyuurip Menggunakan Metode Backpropagation Neural Network,” *J. Media Inform. Budidarma*, vol. 7, pp. 464–472, 2023, doi: 10.30865/mib.v7i1.5499.
- [9] H. Putra and N. Ulfa Walmi, “Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation,” *J. Nas. Teknol. dan Sist. Inf.*, vol. 6, no. 2, pp. 100–107, 2020, doi: 10.25077/teknosi.v6i2.2020.100-107.
- [10] C. Maisyarah, E. Haryatmi, R. Y. Fajriatifah, and Y. H. Puspita, “Prediksi Penyakit Diabetes menggunakan Algoritma Artificial Neural Network,” *J. Data Sci. Inform.*, vol. 2, no. 1, pp. 46–52, 2022, [Online]. Available: <http://publikasi.bigdatascience.id/index.php/jdsi>
- [11] W. S. Lestari and A. Halim, “Prediksi Kesuksesan Startup Menggunakan Deep Neural Network,” *J. SIFO Mikroskil*, vol. 23, no. 2, pp. 99–110, 2022, doi: 10.55601/jsm.v23i2.885.
- [12] S. Y. Prasetyo, “Prediksi Gagal Jantung Menggunakan Artificial Neural Network,” *J. SAINTEKOM*, vol. 13, no. 1, pp. 79–88, 2023, doi: 10.33020/saintekom.v13i1.379.
- [13] Martono and B. Hendrardi, “Implementasi Algoritme Average-Based Length Dalam Fuzzy Time Series Untuk Memprediksi Pasien Rumah Sakit,” *Politeknosains*, vol. XVIII, no. 2, p. 63, 2019.
- [14] C. Cahyaningtyas, Y. Nataliani, and I. R. Widiyari, “Analisis Sentimen Pada Rating Aplikasi Shopee Menggunakan Metode Decision Tree Berbasis SMOTE,” *Aiti*, vol. 18, no. 2, pp. 173–184, 2021, doi: 10.24246/aiti.v18i2.173-184.
- [15] S. Wagyu and C. Idahm, “K-Nearest Neighbor (K-Nn) Untuk Penanganan Missing Value Pada Data Umkm,” *J. Rekayasa Sist. Inf. dan Teknol.*, vol. 1, no. 2, pp. 54–63, 2023, doi: 10.59407/jrsit.v1i2.77.
- [16] M. R. A. Prasetya, A. M. Priyatno, and Nurhaeni, “Penanganan Imputasi Missing Values pada Data Time Series dengan Menggunakan Metode Data Mining,” *J. Inf. dan Teknol.*, vol. 5, no. 2, pp. 52–62, 2023, doi: 10.37034/jidt.v5i2.324.
- [17] I. L. F. Amien, W. Astuti, and K. M. Lhaksamana, “Perbandingan Metode Naïve Bayes dan KNN (K-Nearest Neighbor) dalam Klasifikasi Penyakit Diabetes,” *e-Proceeding Eng.*, vol. 10, no. 2, pp. 1911–1920, 2023.
- [18] A. Harmain, Paiman, K. Henri, Kusnuri, and D. Maulina, “Normalisasi Data Untuk Efisiensi K-Means Pada Pengelompokkan Wilayah Berpotensi Kebakaran Hutan dan Lahan Berdasarkan Sebaran Titik Panas,” *Teknimedia*, vol. 2, no. 2, pp. 83–89, 2021.
- [19] R. E. Wahyuni, “Optimasi Prediksi Inflasi Dengan Neural Network Pada Tahap Windowing Adakah Pengaruh Perbedaan Window Size,” *Technol. J. Ilm.*, vol. 12, no. 3, p. 176, 2021, doi: 10.31602/tji.v12i3.5181.
- [20] C. C. Aggarwal, *Neural Networks and Deep Learning*. New York: Springer, 2018.
- [21] A. Santoso and S. Hansun, “Prediksi IHSG dengan Backpropagation Neural Network,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 3, no. 2, pp. 313–318, 2019, doi: 10.29207/resti.v3i2.887.
- [22] Saraswati Euis, Umaidah Yuyun, and Voutama Apriande, “Penerapan Algoritma Artificial Neural Network untuk Klasifikasi Opini Publik Terhadap Covid-19,” *Gener. J.*, vol. 5, no. 2, pp. 109–118, 2021, doi: 10.29407/gj.v5i2.16125.
- [23] Hernadewita, Y. K. Hadi, M. J. Syaputra, and D. Setiawan, “Peramalan Penjualan Obat Generik Melalui Time Series Forecasting Model Pada Perusahaan Farmasi di Tangerang: Studi Kasus,” *J. Ind. Eng. Manag. Res. (Jiemar)*, vol. 1, no. 2, pp. 35–36, 2020, [Online]. Available: <https://jiemar.org/index.php/jiemar/article/view/38>