



## Prediksi Kuantitas Penggunaan Obat pada Layanan Kesehatan Menggunakan Algoritma Backpropagation Neural Network

Fajrul Khairati<sup>1✉</sup>, Hasdi Putra<sup>2</sup>

<sup>1</sup>Universitas Adzka Padang

<sup>2</sup>Departemen Sistem Informasi Universitas Andalas Padang

[khairatif@gmail.com](mailto:khairatif@gmail.com)

### Abstract

Prediction of the amount of drug use at public health centers is needed to ensure the availability of drugs for patients in service quality management. A good prediction of the amount of medicine needed helps the quality of development planning in the health sector. Scientific developments in the field of Artificial Intelligence (AI) deliver a variety of the best techniques for making predictions. By adopting the workings of neural networks (neurons) in the human brain or Artificial Neural Network (ANN), the Backpropagation Neural Network (BPNN) algorithm is one of the best algorithms in making predictions, including predicting drug use in health services. The problem of this research is how to design the best architectural model such as the number of neurons in the input layer, hidden layer and other parameters so as to produce predictions with optimal accuracy. This study aims to develop an ANN architectural design with the Backpropagation algorithm to predict the need for drug use. The data used is data on drug use reports from 2015 to 2021 at the Andalas Community Health Center (Puskesmas) Padang City. The steps taken to predict are; collect data, pre-process data and perform analysis, design ANN architecture, make predictions. Learning using the backpropagation algorithm through the initial weight initialization process, activation stage, weight training (weight change) and iteration stage. The proportion of the amount of data used for training is 70% data and 30% for testing data. The results of this study indicate that the best ANN architecture is 12-12-1 with an accuracy of predicting the quantity of drug use reaching 97.87% for paracetamol with a Mean Absolute Percentage Error (MAPE) of 2.13%. The prediction results become a reference for the Puskesmas and the Health Office for service planning and development.


Keywords: Prediction, Drug Use, Artificial Neural Network, Backpropagation, Mean Absolute Percentage Error (MAPE).

### Abstrak

Prediksi jumlah penggunaan obat pada pusat kesehatan masyarakat sangat dibutuhkan untuk menjamin ketersediaan obat bagi pasien dalam manajemen kualitas pelayanan. Prediksi yang baik terhadap jumlah obat yang dibutuhkan turut membantu kualitas perencanaan pembangunan di sektor kesehatan. Perkembangan keilmuan bidang Artificial Intelligence (AI) mengantarkan variasi teknik terbaik untuk melakukan prediksi. Dengan mengadopsi cara kerja jaringan syaraf (*neuron*) pada otak manusia atau Artificial Neural Network (ANN), maka Algoritma Backpropagation Neural Network (BPNN) menjadi salah satu algoritma terbaik dalam melakukan prediksi, termasuk dalam prediksi penggunaan obat dalam pelayanan kesehatan. Masalah penelitian ini adalah bagaimana merancang model arsitektur terbaik seperti jumlah neuron pada input layer, hidden layer dan parameter lainnya sehingga menghasilkan prediksi dengan akurasi yang optimal. Penelitian ini bertujuan untuk mengembangkan rancangan arsitektur ANN dengan algoritma Backpropagation untuk memprediksi kebutuhan penggunaan obat. Data yang digunakan adalah data laporan pemakaian obat tahun 2015 sampai dengan 2021 pada Pusat Kesehatan Masyarakat (Puskesmas) Andalas Kota Padang. Tahapan yang dilakukan untuk memprediksi adalah; mengumpulkan data, pre-processing data dan melakukan analisis, merancang arsitektur ANN, melakukan prediksi. Pembelajaran menggunakan algoritma backpropagation melalui proses insialisasi bobot awal, tahap aktivasi, weight training (perubahan bobot) dan tahap iterasi. Proporsi jumlah data yang digunakan untuk training adalah 70% data dan 30% untuk data testing. Hasil penelitian ini menunjukkan bahwa arsitektur ANN terbaik adalah 12-12-1 dengan akurasi prediksi kuantitas penggunaan obat mencapai 97.87% untuk parasetamol dengan Mean Absolute Percentage Error (MAPE) sebesar 2.13%. Hasil prediksi menjadi rujukan bagi Puskesmas dan Dinas Kesehatan untuk perencanaan dan pengembangan layanan.

Kata kunci: Prediksi, Pemakaian Obat, Artificial Neural Network, Backpropagation, Mean Absolute Percentage Error (MAPE).

*JSISFOTEK is licensed under a Creative Commons 4.0 International License.*



### 1. Pendahuluan

Perkembangan Artificial Neural Network (ANN) sangat memungkinkan untuk melakukan prediksi [1]. Dari data yang ada pada sistem informasi [2], bisa dilakukan pengolahan sehingga menghasilkan

informasi dan pengetahuan menggunakan Machine Learning atau pembelajaran mesin. Himpunan data atau data set bisa dilatih agar mengenali pola tertentu sehingga menjadi informasi yang berguna untuk memperoleh insight atau pengetahuan baru dalam mengambil kebijakan [3].

Artificial Neural Network (ANN) merupakan salah satu metode terbaik dalam memprediksi, termasuk memprediksi kebutuhan obat [4]. Cara kerja yang dilakukan dengan mengadopsi jaringan syaraf pada ANN dapat dilakukan dengan beragam model seperti Multilayer Perceptron (MLP), Deep Neural Network (DNN), Generalized Regression Neural Network (GRNN) atau Monotonic MLP [5], [6]. Namun Neural Network memiliki masalah dalam penentuan jumlah neuron dan hidden layer optimal pada model arsitekturnya [7]. Jumlah neuron pada input layer, hidden layer dan output layer perlu dirancang sedemikian rupa sehingga menghasilkan prediksi terbaik [8].

Modifikasi ANN sudah dilakukan oleh beragam peneliti dengan menggunakan algoritme tertentu untuk melakukan training data seperti algoritme Backpropagation [9], Particle Swarm Optimization [10], K-Means [6] dan lain-lain. Jumlah input layer, hidden layer dan output layer yang diterapkan pada riset terdahulu berbeda untuk masing-masing algoritme agar menghasilkan prediksi terbaik dari data yang diolah. Performa dari kemampuan prediksi dapat diukur dari akurasi, presisi, MAPE atau Mean Absolute Percentage Error, dan lain-lain [11]. Algoritme Backpropagation Neural Network (BPNN) adalah salah satu jenis Artificial Neural Network [12]. Prinsip dasar BPNN adalah mempelajari sampel input, menilai kesalahan, memodifikasi bobot dan nilai ambang batas untuk mengurangi kesalahan, dan kemudian mengulangi berkali-kali untuk mendapatkan hubungan pemetaan yang optimal [13]. BPNN terdiri dari banyak lapisan, termasuk lapisan masukan, lapisan tersembunyi, dan lapisan keluaran [14].

Masalah yang akan diselesaikan dengan penggunaan ANN pada penelitian ini adalah untuk merancang model arsitektur terbaik dan melakukan prediksi kebutuhan obat pada Pusat Kesehatan Masyarakat (Puskesmas) Andalas Kota Padang, Provinsi Sumatera Barat. Puskesmas memerlukan prediksi kebutuhan obat untuk manajemen obat agar dapat mengoptimalkan layanan kesehatan [9]. Menggunakan prediksi kebutuhan obat yang akurat, Puskesmas dan institusi kesehatan menjadi lebih mudah untuk mengelola persediaan obat, mengantisipasi kelangkaan [15], mengefisiensikan anggaran ataupun menghindari kadaluarsa untuk mengoptimalkan layanan [16]. Apalagi kelangkaan obat merupakan situasi kritis dalam layanan kesehatan yang harus diantisipasi secara baik [17]. Sehingga pihak manajemen rumah sakit harus melengkapi sistem informasi manajemen rumah sakit dengan prediksi kebutuhan obat untuk pelayanan kesehatan yang maksimal [15].

Penelitian penerapan ANN Backpropagation sudah dilakukan pada beragam keperluan. Prediksi permintaan garam pada PT. Kurnia Garam Sejahtera Kota Padang, dimana hasil momentum yang didapatkan adalah 3-9-1 dan hasil prediksi yang

optimal adalah 0,98946 [18]. Prediksi produksi padi di Sumatera Barat diperoleh berupa rancangan optimal untuk melakukan prediksi menggunakan multilayer dengan tingkat akurasi mencapai 88,14% atau dengan tingkat error 11,86% [19]. Pada saat melakukan konfigurasi ANN [20] menguraikan tentang nilai-nilai pada variable pada proses prediksi kebutuhan obat. Nilai seperti jumlah hidden layer, target momentum, learning rate, maksimum epoch juga dijelaskan. Konfigurasi yang dilakukan dengan variasi nilai parameter menjadikan pengembangan arsitektur neural network sebagai salah satu hal penting untuk dapat menghasilkan prediksi terbaik.

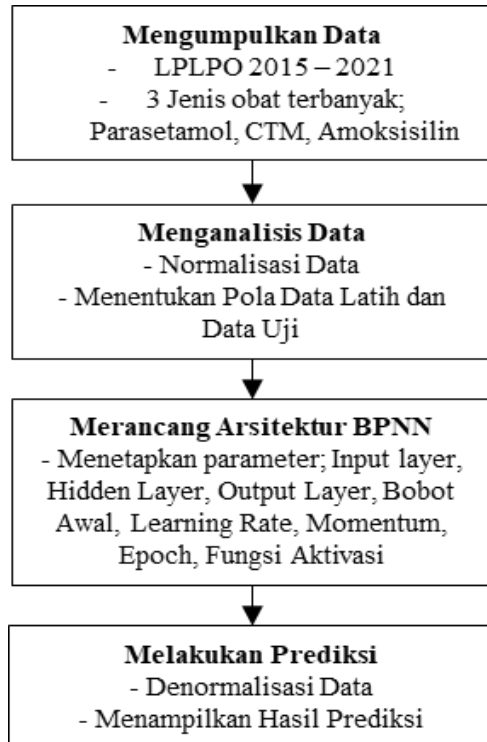
Pada bidang kesehatan, khususnya prediksi kebutuhan obat [21] telah menganalisis penggunaan Backpropagation dalam memprediksi kebutuhan obat. Hasil yang prediksi yang diperoleh mencapai 88,0356% atau MAPE 11,0964% dengan epoch 900 dan learning rate 0,001 dengan jumlah neuron sebanyak 9 (sembilan). Prediksi kebutuhan stok obat pada Puskesmas Dumai Barat menggunakan metode jaringan saraf tiruan backpropagation untuk menentukan kebutuhan obat, akurasi 88,10426% atau nilai Mean Absolute Percentage Error (MAPE) 11,9644% dan nilai Mean Square Error (MSE) adalah 0,10426 [22]. Pada Puskesmas yang sama, [23], [1] melakukan prediksi kebutuhan obat menggunakan metode Learning Vector Quantization. Hasil prediksinya menunjukkan akurasi yang tidak jauh lebih baik dari Backpropagation yaitu 78,57%. Data yang diolah dengan perbandingan 56 data latih dan 14 data uji, atau dengan kata lain 80% data latih berbanding 20% data uji. Arsitektur terbaik yang diperoleh adalah dengan 6 neuron pada input layer, 10 neuron pada hidden layer dan 10 neuron pada output layer. Hasil ini semakin mempertegas bahwa menggunakan Neural Network masih lebih baik 10% seperti pada [21] atau [22].

Pada penerapan prediksi, konfigurasi arsitektur neural network sangat mempengaruhi akurasi yang dilakukan. Pengaruh jumlah hidden layer dalam melakukan prediksi pada kebutuhan obat captopril dan paracetamol di rumah sakit, dengan jumlah neuron hidden layer 50 dan 75 berhasil mendapatkan nilai akurasi sebesar 74,89% untuk jenis obat Captopril, kemudian arsitektur menggunakan jumlah neuron hidden layer menjadi 20 dan 15 jenis obat. Parasetamol menghasilkan 86,21% [24].

Berdasarkan latar belakang yang dijabarkan di atas, maka dari itu dilakukan penelitian dengan judul Pengembangan Arsitektur Neural Network Untuk Prediksi Kebutuhan Obat Pada Pusat Kesehatan Masyarakat (Puskesmas) Andalas Kota Padang. Menggunakan konfigurasi arsitektur neural network yang dikembangkan melalui penelitian diharapkan dapat menghasilkan akurasi prediksi yang lebih baik untuk perbaikan layanan Kesehatan dalam mengelola persediaan obat yang dibutuhkan.

## 2. Metodologi Penelitian

Penelitian ini dilakukan pada Pusat Kesehatan Masyarakat (Puskesmas) Andalas Kota Padang. Tahapan yang dilakukan untuk prediksi jumlah penggunaan obat adalah; mengumpulkan data, menganalisis data, merancang arsitektur ANN, melatih dan memprediksi jumlah penggunaan obat. Tahapan ini disajikan pada Gambar 1.



Gambar 1. Tahapan Prediksi Penggunaan Obat dengan BPNN

### 2.1. Mengumpulkan data

Data yang dikumpulkan bersumber dari Laporan Pemakaian dan Lembar Permintaan Obat (LPLPO) dari tahun 2015 – 2021. Tiga jenis obat yang terbanyak digunakan sebagai sampel untuk prediksi, yaitu; Parasetamol, Chlorpheniramine Maleate (CTM) dan Amoksisilin.

### 2.2. Menganalisis Data

Data yang sudah dikumpulkan dianalisis dengan melakukan normalisasi dan menentukan pola data. Normalisasi dilakukan dengan melakukan transformasi data sesuai dengan fungsi aktivasi yang digunakan. Dalam penelitian menggunakan fungsi aktivasi *sigmoid biner* dan *linear* atau identitas.

Setelah data dinormalisasi, pola data latih (*training*) dan data uji (*testing*) ditentukan. Pola data memiliki pengaruh yang besar terhadap hasil prediksi yang akan diperoleh, karena perubahan bobot terkadang menjadi sangat besar jika model dari pola baru yang dilatih sangat berbeda dengan pola sebelumnya sehingga menghasilkan hasil yang akurat.

Pada penelitian ini digunakan fungsi aktivasi *sigmoid biner* yang mempunyai *range* pada interval [0.1, 0.9]. Karena fungsi *sigmoid* merupakan fungsi asimtotik yang nilainya tidak pernah mencapai 0 ataupun 1. pembagian dari data aktual yang digunakan dalam penelitian ini yaitu 70% data untuk *training* dan 30% data untuk *testing*.

### 2.3. Merancangan Model Arsitektur BPNN

Pada perancangan arsitektur model ANN yang optimal, ditetapkan beberapa parameter yaitu: penentuan jumlah input, penentuan jumlah neuron pada hidden layer berdasarkan percobaan, penentuan fungsi aktivasi yang digunakan, learning rate, dan penentuan bobot dan bias awal yang digunakan.

### 2.4. Melakukan Prediksi

Setelah data valid, dan arsitektur model ANN telah disiapkan, maka dilakukan prediksi dengan metode algoritma Backpropagation. Lalu akan didapatkan hasil prediksi, grafik hasil, MAPE, dan akurasi. Setelah proses prediksi, maka didapatkan nilai output atau hasil prediksi, dimana data awal sebagai data input telah dilakukan proses normalisasi. Jadi untuk data prediksi yang baru dihasilkan perlu dilakukan proses denormalisasi. Proses ini disebut dengan post-processing yaitu proses dimana akan mengembalikan nilai tersebut sesuai dengan data awal.

Pembelajaran menggunakan algoritma backpropagation melalui proses inialisasi bobot awal, tahap aktivasi, weight training (perubahan bobot) dan tahap iterasi. Inialisasi maksudnya memberikan nilai awal terhadap nilai-nilai yang diperlukan oleh neural network seperti weight, threshold [25]. Nilai-nilai yang diberikan pada tahap inialisasi digunakan pada tahap aktivasi dengan melakukan perhitungan aktual output pada hidden layer dan menghitung aktual output pada output layer. Pada tahap weight training dilakukan perhitungan error gradien pada output layer dan menghitung error gradien pada hidden layer. Pada iterasi dilakukan proses pengulangan sampai mendapat error yang minimal.

## 3. Hasil dan Pembahasan

Prediksi jumlah pemakaian obat pada layanan kesehatan menggunakan algoritma Backpropagation, dilakukan dengan mengolah data Laporan Pemakaian dan Lembar Permintaan Obat (LPLPO) yang dikeluarkan setiap bulan oleh pusat kesehatan masyarakat (Puskesmas) sesuai tahapan pada Gambar 1.

### 3.1. Data

Data jumlah penggunaan pada Pusat Kesehatan Masyarakat (Puskesmas) Andalas Kota Padang tahun 2015 – 2021 disajikan pada Tabel 1. Pada makalah ini ditampilkan data untuk obat Parasetamol. Untuk obat CTM dan obat Amoksisilin dilakukan proses yang sama agar bisa melakukan prediksi.

Tabel 1. Kuantitas Penggunaan Obat Parasetamol (tablet) Tahun 2015-2021

Bulan	2015	2016	2017	2018	2019	2020	2021
Januari	12748	13855	12595	12687	12514	14269	13377
Februari	13958	13048	12958	12264	13579	13595	12671
Maret	12857	13068	13650	13950	13531	12007	13241
April	13486	12187	14038	12960	14385	12159	12628
Mei	13064	13439	13086	12652	14589	12758	13106
Juni	13046	13957	13205	12925	12782	13715	12684
Juli	12460	12576	14038	13472	12405	12939	14255
Agustus	13778	12879	13216	13962	12043	13671	13834
September	12859	12086	13200	13548	13035	13388	13110
Oktober	13091	13958	12549	12288	13469	14149	14480
November	13849	13404	12475	14013	14013	14319	13261
Desember	13687	13902	12913	14223	14259	14275	14207

### 3.2. Normalisasi Data

Normalisasi data dilakukan dengan menggunakan Rumus (1).

$$x' = \frac{0.8(x - a)}{b - a} + 0,1 \quad (1)$$

Dimana x' adalah hasil data yang telah dinormalisasi, x adalah data yang akan dinormalisasi, a adalah data minimum, dan b adalah data maksimum.

Pada bulan Januari tahun 2015, jumlah pemakaian obat parasetamol adalah 12748 tablet. Jumlah pemakaian maksimum 14589 tablet, dan minimum 12007 tablet. Maka hasil normalisasinya adalah;  $x' = 0.8 \cdot (12748 - 12007) / (14589 - 12007) + 0.1 = 0.3296$ . Artinya jumlah pemakaian 12748 tablet dinormalisasi menjadi 0.3296. Hasil normalisasi data untuk obat parasetamol secara lengkap disajikan pada Tabel 2.

Tabel 2. Data Normalisasi Obat Parasetamol Tahun 2015-2021

Bulan	2015	2016	2017	2018	2019	2020	2021
Januari	0.3296	0.6726	0.2822	0.3107	0.2571	0.8009	0.5245
Februari	0.7045	0.4225	0.3947	0.1796	0.5871	0.5920	0.3057
Maret	0.3634	0.4287	0.6091	0.7020	0.5722	0.1000	0.4823
April	0.5582	0.1558	0.7293	0.3953	0.8368	0.1471	0.2924
Mei	0.4275	0.5437	0.4343	0.2998	0.9000	0.3327	0.4405
Juni	0.4219	0.7042	0.4712	0.3844	0.3401	0.6292	0.3098
Juli	0.2404	0.2763	0.7293	0.5539	0.2233	0.3888	0.7965
Agustus	0.6487	0.3702	0.4746	0.7057	0.1112	0.6156	0.6661
September	0.3640	0.1245	0.4696	0.5775	0.4185	0.5279	0.4418
Oktober	0.4359	0.7045	0.2679	0.1871	0.5530	0.7637	0.8662
November	0.6707	0.5328	0.2450	0.7215	0.7215	0.8163	0.4885
Desember	0.6205	0.6871	0.3807	0.7866	0.7978	0.8027	0.7816

### 3.3. Penentuan Pola Data Latih dan Data Uji

Setelah data dinormalisasi, dilanjutkan dengan menentukan pola data latih (training) dan pola data uji (testing). Pola yang dipakai dalam penelitian ini merupakan data obat selama 12 bulan dan target adalah data obat pada bulan ke-13, begitu seterusnya. Data aktual yang digunakan dalam penelitian ini yaitu 70% data untuk training dan 30% data untuk testing. Sehingga data latih berjumlah 58 data dan data uji berjumlah 26 data untuk satu jenis obat. Perbandingan ini mirip dengan yang dilakukan pada penelitian sebelumnya [19].


### 3.4. Perancangan Model Arsitektur ANN

a. Arsitektur ANN yang digunakan yaitu multilayer yang terdiri dari input layer, hidden layer, dan output layer. Input layer yang digunakan adalah 12 neuron yang merupakan jumlah bulan dalam satu tahun. Sedangkan hidden layer berjumlah 12 neuron yang

diperoleh dari proses trial dan error. Sedangkan output layer adalah 1 neuron yang menunjukkan prediksi jumlah pemakaian obat. Rincian rancangan arsitektur model ANN ditunjukkan pada Tabel 3 dan rancangan disajikan pada Gambar 2.

Tabel 3. Rancangan Arsitektur Model ANN

Parameter	Jumlah	Keterangan
Input Layer	12 Neuron	Data obat selama 12 bulan
Hidden Layer	Trial and error	12 neuron
Output Layer	1 Neuron	Jumlah pemakaian obat
Bobot Awal	Trial and error	Batas Bawah: 0.05 Batas Atas : 0.08 Bilangan acak antara 0.05-0.08
Learning Rate	Trial and error	0.1-0.5
Momentum	Trial and error	0.5-0.9
Epoch	Trial and error	1000
Fungsi Aktivasi	2	Logsig dan Purelin



Gambar 2. Arsitektur model ANN 12-12-1

Arsitektur model yang dipakai adalah 12-12-1, yaitu 12 neuron input, 12 neuron hidden layer dan 1 neuron output. Arsitektur ANN pada Gambar 2 terdapat simbol simbol yang digunakan dalam algoritma backpropagation. Simbol tersebut disajikan pada Tabel 4.

Tabel 4. Simbol-simbol pada algoritma backpropagation

Simbol	Keterangan
$X$	Input vektor pelatihan, $x_i$ ( $i = 1,2,3,\dots,n$ )
$Y$	Output vektor target, $y_k$ ( $k = 1,2,\dots,m$ )
$x_i$	Unit input $i$
$z_{netj}$	Input jaringan ke $z_j$
$v_{j0}$	Bias pada lapisan tersembunyi $j$
$v_{ji}$	Bobot yang menghubungkan input layer dan hidden layer
$z_j$	Unit tersembunyi $j$
$y_{netk}$	Input jaringan ke $y_k$
$Y_k$	Unit output $k$
$\delta_k$	Informasi tentang kesalahan pada unit $y_k$ yang disebarkan kembali ke unit tersembunyi
$t_k$	Vektor target
$\delta_j$	Informasi tentang kesalahan antara lapisan tersembunyi $z_j$ ke lapisan input.
$\alpha$	Laju pembelajaran ( <i>learning rate</i> )
$w_{ko}$	Bias pada unit output $k$
$w_{kj}$	Bobot yang menghubungkan hidden layer dan output layer
$\mu$	Momentum

b. Untuk merancang sebuah jaringan ANN dengan algoritma backpropagation, terlebih dahulu dilakukan inisialisasi bobot input awal, bias input awal, bobot output awal, dan bias output awal dengan bilangan acak kecil yang diberikan batas atas 0,08 dan batas bawah 0,05 yang dipilih secara otomatis di aplikasi MATLAB. Fungsi aktivasi pada hidden layer pada proses pelatihan adalah *logsig*, dan fungsi aktivasi pada output layer adalah *purelin*.

c. Bobot diambil dari nilai random yang cukup kecil, biasanya bobot awal diinisialisasi dengan nilai antara -0.5 sampai 0.5 (atau -1 sampai 1). Setelah melakukan trial and error, maka nilai yang tepat untuk dijadikan bobot awal yaitu 0.05 dan 0.08.

d. Parameter laju pembelajaran (*learning rate*) berguna untuk mempercepat laju iterasi (*epoch*). Bila nilai

learning rate-nya semakin kecil, maka ketelitian/keakuratan akan semakin besar, namun terdapat resiko yaitu proses iterasi akan memakan waktu yang semakin lama). Karena jumlah learning rate ditentukan dengan proses trial and error maka rentang nilai untuk learning rate adalah 0,1 hingga 0.5

e. Parameter momentum dimaksudkan untuk menghindari perubahan bobot yang mencolok akibat adanya data yang sangat berbeda dengan yang lain. Dengan melakukan perubahan momentum akan berdampak terhadap waktu proses, jadi semakin besar nilai momentum maka semakin cepat waktu proses yang terjadi. Karena menggunakan proses trial and error maka momentum dilakukan dengan rentang nilai dari 0.5 - 0.9.

f. Parameter epoch (*iterasi*) sebagai parameter perulangan untuk pemberhentian pada proses pelatihan. Apabila jumlah iterasi telah mencapai jumlah maksimum maka pelatihan akan berhenti. Jika maksimum epoch tinggi, maka memerlukan waktu yang lama dalam melakukan pelatihan dan jika epoch rendah, maka tidak dihasilkan akurasi yang baik. Dengan menggunakan proses trial and error maka untuk prediksi ini diberi maksimum 1000 epochs.

Dengan menggunakan parameter pada rancangan arsitektur ANN, maka hasil pengujian rancangan ANN dengan parameter epoch, learning rate, momentum, untuk obat parasetamol disajikan pada Tabel 5.

### 3.5. Prediksi Kuantitas Penggunaan Obat

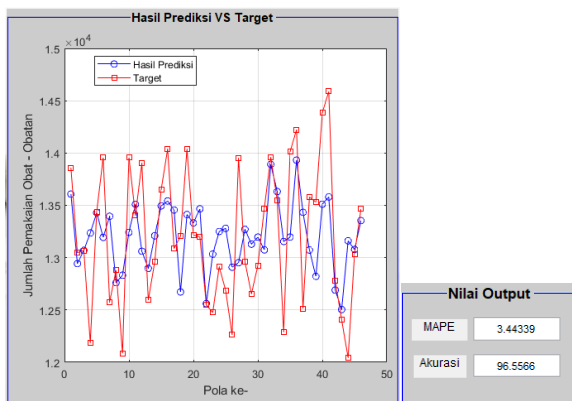
Prediksi kuantitas penggunaan obat dilakukan dengan menggunakan parameter terbaik yang dihasilkan dari data latih. Prediksi kuantitas penggunaan obat dilakukan untuk obat parasetamol ini diambil 1000 epochs, karena sudah bisa mencapai hasil yang baik. Nilai untuk learning rate yang diuji adalah 0.1 – 0.5. Semakin kecil learning rate, maka akurasi prediksi semakin besar. Nilai momentum 0.5 – 0.9. Semakin besar nilai momentum dari suatu proses maka semakin cepat waktu proses prediksi yang terjadi. Akurasi

prediksi diperoleh dari 100% dikurangi dengan nilai MAPE.

Tabel 5. Hasil Pengujian Parameter Obat Parasetamol

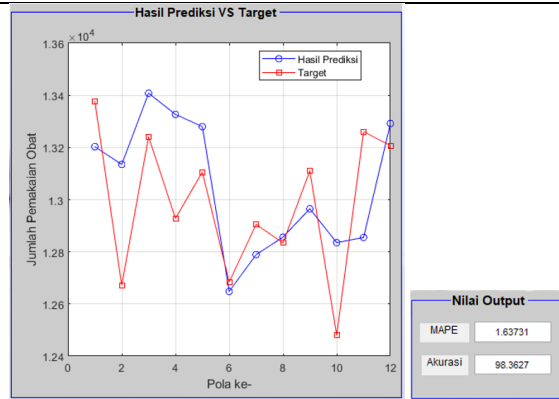
Epoch	Learning Rate	Momen tum	MAPE (%)	Akurasi (%)
	0,1	0,5	4.2470	95.7530
		0,6	4.1457	95.8543
		0,7	4.1422	95.8578
		0,8	4.0601	95.9399
		<b>0,9</b>	<b>3.4434</b>	<b>96.5566</b>
	0,2	0,5	4.2061	95.7939
		0,6	4.1299	95.8701
		0,7	4.0735	95.9265
		0,8	4.0145	95.9855
		0,9	3.9350	96.0650
1000	0,3	0,5	4.2000	95.8000
		0,6	4.1462	95.8538
		0,7	4.0782	95.9218
		0,8	4.0596	95.9404
		0,9	3.9404	96.0596
	0,4	0,5	4.2613	95.7387
		0,6	4.1316	95.8684
		0,7	4.1259	95.8741
		0,8	4.1073	95.8927
		0,9	3.9731	96.0269
0,5	0,5	4.2038	95.7962	
	0,6	4.1384	95.8616	
	0,7	4.0899	95.9101	
	0,8	4.0215	95.9785	
		0,9	3.9554	96.0446

Dari Tabel 5 dapat dilihat bahwa hasil pengujian parameter terbaik untuk model ANN obat parasetamol terdapat pada 1 hidden layer dan 12 node (neuron), epoch 1000, learning rate 0,1, momentum 0,9 dengan nilai MAPE 3,44% dan tingkat akurasi sebesar 96,56%. Berdasarkan skala MAPE yang diperoleh yaitu kecil dari 10% maka, kinerja dari model dinilai sangat baik. Berikut ini adalah grafik hasil pelatihan terbaik dapat dilihat pada Gambar 3.



Gambar 3. Hasil Pelatihan Obat Parasetamol

Dari Gambar 3 dapat dilihat bahwa hasil pelatihan terbaik untuk obat parasetamol dengan nilai MAPE 3,44% dan tingkat akurasi 96,56%. Grafik hasil prediksi dapat dilihat pada Gambar 4 berikut ini.



Gambar 4. Hasil Prediksi Obat Parasetamol

Dari Gambar 4 menunjukkan hasil prediksi untuk obat parasetamol dengan nilai MAPE 1,64% dan tingkat akurasi 98,36%. Perbandingan data aktual dengan data hasil prediksi disajikan pada Gambar 5.

	Target	Prediksi	MAPE
Januari	13377	13203	1.3007
Februari	12671	13135	3.6619
Maret	13241	13408	1.2612
April	12928	13327	3.0863
Mei	13106	13280	1.3276
Juni	12684	12648	0.2838
Juli	12905	12789	0.8989
Agustus	12834	12856	0.1714
September	13110	12965	1.1060
Oktober	12480	12835	2.8446
November	13261	12855	3.0616
Desember	13207	13292	0.6436

Gambar 5. Hasil Prediksi Parasetamol Tahun 2022

Dari Gambar 5 diperoleh prediksi jumlah kebutuhan obat parasetamol untuk tahun 2022. Akurasinya mencapai 98,36%. Hasil ini sebanding dengan tingkat akurasi yang diperoleh pada [21], [22]. Dengan metode dan cara yang sama, prediksi ini dapat dilakukan untuk stok obat yang lainnya. Parameter rancangan arsitektur ANN terbaik untuk prediksi jumlah pemakaian obat dapat dilihat pada Tabel 7.

Tabel 7. Nilai Epoch, Learning Rate, Momentum, MAPE dan Akurasi Hasil Prediksi

Nama Obat	Epoch	LR	Momen tum	MAPE (%)	Akurasi (%)
Parasetamol	1000	0,1	0,9	1.64	98,36
CTM	1000	0,1	0,9	3.14	96,86
Amoksisilin	1000	0,1	0,9	2.72	97,28

Dengan rancangan pada Tabel 7, prediksi untuk obat yang lain dapat dilakukan. Prediksi yang dilakukan untuk jumlah pemakaian obat-obatan telah berhasil dilakukan menggunakan perangkat lunak MATLAB. Data input diambil dari data pemakaian obat tahun 2015-2021 dan menghasilkan output data jumlah pemakaian obat tahun 2022. Hasil prediksi kebutuhan penggunaan obat tahun 2022 ditunjukkan pada Tabel 8.

Tabel 8. Prediksi Jumlah Kebutuhan Obat tahun 2022

Parasetamol	CTM	Amoksisilin
13203	7.301	6.394
13135	7.386	6.133
13408	7.409	6.296
13327	7.495	6.370
13280	7.448	6.541
12648	7.405	6.571
12789	7.677	6.531
12856	7.407	6.591
12965	7.725	6.422
12835	7.497	6.359
12855	7.467	6.269
13292	7.474	6.350

#### 4. Kesimpulan

Prediksi kuantitas penggunaan obat menggunakan algoritma Backpropagation Neural Network (BPNN) sudah berhasil dikembangkan dengan rancangan yang sudah diterapkan pada aplikasi menggunakan MATLAB. Aplikasi telah mampu melakukan prediksi jumlah pemakaian obat untuk tahun 2022. Dengan melakukan pengujian terhadap parameter pada rancangan model prediksi sehingga diperoleh rancangan dengan model yang optimal untuk setiap jenis obatnya meliputi, *input layer* berjumlah 12, *hidden layer* berjumlah 1 dengan 12 *node*, dan *output layer* berjumlah 1, *epoch* sebesar 1000, *momentum* sebesar 0,9 dan *learning rate* sebesar 0,1. Dari penelitian dapat disimpulkan bahwa nilai keakuratan atau tingkat akurasi sistem prediksi jumlah pemakaian obat sebesar 98,36% untuk parasetamol, 96,86% untuk CTM, 97,28% untuk amoksisilin.

#### Daftar Rujukan

- [1] Kolluri, S., Lin, J., Liu, R., Zhang, Y., & Zhang, W. (2022). Machine Learning and Artificial Intelligence in Pharmaceutical Research and Development: a Review. *Injury*, 1–10. <https://doi.org/10.1016/j.injury.2022.01.046>
- [2] Abbas, K., Afaq, M., Khan, T. A., & Song, W. C. (2020). A blockchain and machine learning-based drug supply chain management and recommendation system for smart pharmaceutical industry. *Electronics (Switzerland)*, 9(5), 1–31. <https://doi.org/10.3390/electronics9050852>
- [3] He, B., Han, W., & Hon, S. Y. I. (2022). A Machine Learning Approach: Enhancing the Predictive Performance of Pharmaceutical Stock Price Movement during COVID. *Journal of Data Analysis and Information Processing*, 10(01), 1–21. <https://doi.org/10.4236/jdaip.2022.101001>
- [4] Thakkar, A., & Chaudhari, K. (2021). A comprehensive survey on deep neural networks for stock market: The need, challenges, and future directions. In *Expert Systems with Applications (Vol. 177)*. <https://doi.org/10.1016/j.eswa.2021.114800>
- [5] Safari, A., & Ghavifekr, A. A. (2021). International Stock Index Prediction Using Artificial Neural Network (ANN) and Python Programming. 2021 7th International Conference on Control, Instrumentation and Automation, ICCIA 2021. <https://doi.org/10.1109/ICCIA52082.2021.9403580>
- [6] Wang, S., Di, J., Wang, D., Dai, X., Hua, Y., Gao, X., Zheng, A., & Gao, J. (2022). State-of-the-Art Review of Artificial Neural Networks to Predict, Characterize and Optimize

- Pharmaceutical Formulation. *Pharmaceutics*, 14(1), 183. <https://doi.org/10.3390/pharmaceutics14010183>
- [7] Wang, H., Hong, M., & Hong, Z. (2021). Research on BP Neural Network Recommendation Model Fusing User Reviews and Ratings. *IEEE Access*, 9, 86728–86738. <https://doi.org/10.1109/ACCESS.2021.3080079>
- [8] Sijabat, P. I., Yuhandri, Y., Nurcahyo, G. W., & Sindar, A. (2020). Algoritma Backpropagation Prediksi Harga Komoditi terhadap Karakteristik Konsumen Produk Kopi Lokal Nasional. *Digital Zone: Jurnal Teknologi Informasi Dan Komunikasi*, 11(1), 96-107.
- [9] Du, M., Luo, J., Wang, S., & Liu, S. (2020). Genetic algorithm combined with BP neural network in hospital drug inventory management system. *Neural Computing and Applications*, 32(7), 1981–1994. <https://doi.org/10.1007/s00521-019-04379-3>
- [10] Jamous, R., Alrahal, H., & El-Dariby, M. (2021). A New ANN-Particle Swarm Optimization with Center of Gravity (ANN-PSOCoG) Prediction Model for the Stock Market under the Effect of COVID-19. *Scientific Programming*, 2021, 1–17. <https://doi.org/10.1155/2021/6656150>
- [11] Zhu, T., Li, K., Herrero, P., & Georgiou, P. (2021). Deep Learning for Diabetes: A Systematic Review. *IEEE Journal of Biomedical and Health Informatics*, 25(7), 2744–2757. <https://doi.org/10.1109/JBHI.2020.3040225>
- [12] Wei, W., & Yang, X. (2021). Comparison of diagnosis accuracy between a backpropagation artificial neural network model and linear regression in digestive disease patients: An empirical research. *Computational and Mathematical Methods in Medicine*, 2021. <https://doi.org/10.1155/2021/6662779>
- [13] Zhang, H., & Mu, J.-H. (2021). A Back Propagation Neural Network-Based Method for Intelligent Decision-Making. *Complexity*, 2021, 1–11. <https://doi.org/10.1155/2021/6610797>
- [14] Wang, G., Jia, Q. S., Zhou, M., Bi, J., Qiao, J., & Abusorrah, A. (2021). Artificial neural networks for water quality soft-sensing in wastewater treatment: a review. *Artificial Intelligence Review*, 1-23. <https://doi.org/10.1007/s10462-021-10038-8>
- [15] Shukla, P. K., Shukla, P. K., Sharma, P., Rawat, P., Samar, J., Moriwat, R., & Kaur, M. (2020). Efficient prediction of drug–drug interaction using deep learning models. *IET Systems Biology*, 14(4), 211–216. <https://doi.org/10.1049/iet-syb.2019.0116>
- [16] Manni, A., Saviano, G., & Bonelli, M. G. (2021). Optimization of the ANNs Predictive Capability Using the Taguchi Approach: A Case Study. *Mathematics*, 9(7), 1–16. <https://doi.org/10.3390/math9070766>
- [17] Zwaيدا, T. A., Pham, C., & Beaugard, Y. (2021). Optimization of inventory management to prevent drug shortages in the hospital supply chain. *Applied Sciences (Switzerland)*, 11(6). <https://doi.org/10.3390/app11062726>
- [18] Thoriq, M. (2022). Peramalan Jumlah Permintaan Produksi Menggunakan Jaringan Saraf Tiruan Algoritma Backpropagation. *Jurnal Informasi Dan Teknologi*, 4, 27–32. <https://doi.org/10.37034/jidt.v4i1.178>
- [19] Putra, H., & Walmi, N. U. (2020). Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 6(2), 100–107. <https://doi.org/10.25077/teknosi.v6i2.2020.100-107>
- [20] Abdullah, D., Pardede, A. M. H., Umami, L., Manurung, R., Suryani, R., Surya, S., Saddhono, K., Mulyaningsih, I., Sudarsana, I. K., Brata, D., Mahatmaharti, R. A. K., Novziransyah, N., Amalia, A., Effendi, S., Samidah, I., & Murwati, M. (2020). Drug Users Prediction Using Backpropagation Educational Method. *Journal of Physics:*

- Conference Series, 1361(1). <https://doi.org/10.1088/1742-6596/1361/1/012055>
- [21] Elisawati, E., Linarta, A., Putra, A. M. I., & Elvaningsih, H. (2022). Analysis of Backpropagation Method in Predicting Drug Stock. *Sinkron*, 7(2), 297–307. <https://doi.org/10.33395/sinkron.v7i2.11269>
- [22] Elvaningsih, H., Elisawati, Tawakal, F., & Masrizal. (2021). Prediksi Stok Obat Menggunakan Metode Backpropagation (Studi Kasus: Puskesmas Dumai Barat). *Seminar Nasional Sains Dan Teknologi Informasi (SENSASI)*, 228–232. <https://prosiding.seminar-id.com/index.php/sensasi/article/view/588/569>
- [23] Abdianto, D., Elisawati, Tawakal, F., & Masrisal. (2021). Prediksi Stok Obat Menggunakan Metode Learning Vector Quantization Studi Kasus Puskesmas Dumai Barat. *Prosiding SNST*, Volume 1, 68–74.
- [24] Wibowo, P., Suryono, S., & Gunawan, V. (2019). Pengaruh Perbedaan Jumlah Hidden Layer dalam Jaringan Syaraf Tiruan Terhadap Prediksi Kebutuhan Captopril dan Paracetamol pada Rumah Sakit. *Jurnal Media Aplikom*, 11(2), 45–58.
- [25] S. H. Putri, Y. Yuhandri, and G. W. Nurcahyo, “Prediksi Pencapaian Target Peserta Keluarga Berencana Pasca Persalinan menggunakan Algoritma Backpropagation,” *Jurnal Sistim Informasi dan Teknologi*, vol. 3, pp. 176–182, 2021, doi: [10.37034/jsisfotek.v3i3.62](https://doi.org/10.37034/jsisfotek.v3i3.62).
- [26] W. Satria, “Jaringan Syaraf Tiruan Backpropagation Untuk Peramalan Penjualan Produk (Studi Kasus Di Metro Electronic Dan Furniture),” *Djtechno J. Teknol. Inf.*, vol. 1, no. 1, pp. 14–19, Jun. 2021, doi: [10.46576/djtechno.v1i1.966](https://doi.org/10.46576/djtechno.v1i1.966).