

# Pendekatan Backpropagation Artificial Neural Network Untuk Prediksi Kemurnian Madu

*Artificial Neural Network Backpropagation Approach for Honey Purity Prediction*

**Andi Muh Ihsanul Tafsir<sup>1</sup>, Sulfayanti<sup>2</sup>, Nahya Nur<sup>3</sup>**

<sup>1,2,3</sup>*Program Studi Informatika, Universitas Sulawesi Barat, Majene, Sulawesi Barat*

*E-mail:* a.muhhsanultafsir@mhs.unsulbar.ac.id<sup>1</sup>, sulfayanti@unsulbar.ac.id<sup>2</sup>,

*nahya.nur@unsulbar.ac.id<sup>3</sup>*

Received 7 October 2025; Revised 29 October 2025; Accepted 7 November 2025

**Abstrak** - Madu merupakan produk alami yang kemurniannya menjadi indikator utama kualitas dan keasliannya. Penelitian ini bertujuan untuk memprediksi tingkat kemurnian madu menggunakan algoritma *Artificial Neural Network* (ANN) dengan metode *Backpropagation*. *Dataset* terdiri dari 247.903 data dengan 10 atribut madu yang digunakan sebagai variabel *input*, sedangkan tingkat kemurnian madu dijadikan sebagai target *output*. Tahapan penelitian meliputi pra-pemrosesan data, pelatihan model, serta evaluasi hasil prediksi. Setelah melalui tahap pra-pemrosesan, jumlah fitur *input* bertambah menjadi 27. Pada proses eksperimen, dilakukan pengujian beberapa variasi arsitektur (27-14-14-1, 27-27-27-1, 27-54-54-1), fungsi aktivasi (*ReLU*, *sigmoid* biner, *sigmoid* bipolar), *learning rate* (0,01, 0,1, 0,5), dan jumlah epoch (1000, 1500, 2000) untuk memperoleh konfigurasi terbaik. Hasil optimal diperoleh pada arsitektur jaringan 27-54-54-1 dengan fungsi aktivasi *ReLU*, *learning rate* 0,5, dan jumlah *epoch* sebanyak 2000. Konfigurasi tersebut menghasilkan kinerja prediksi dengan nilai *Mean Squared Error* (MSE) 0,000542, *R-squared* (*R*<sup>2</sup>) sebesar 0,972010, dan *Mean Absolute Percentage Error* (MAPE) 1,26%. Hasil ini membuktikan bahwa algoritma *Backpropagation Artificial Neural Network* dapat digunakan secara efektif dalam memprediksi tingkat kemurnian madu.

**Kata Kunci** - *Artificial Neural Network, Backpropagation, Prediksi, Kemurnian Madu*

**Abstract** – Honey is a natural product whose purity serves as a primary indicator of its quality and authenticity. This study aims to predict the purity level of honey using the Artificial Neural Network (ANN) algorithm with the Backpropagation method. The dataset consists of 247,903 records with 10 honey attributes used as input variables, while the honey purity level is set as the target output. The research stages include data preprocessing, model training, and prediction evaluation. After preprocessing, the number of input features increased to 27. In the experimental process, several variations of network architectures (27-14-14-1, 27-27-27-1, 27-54-54-1), activation functions (*ReLU*, binary *sigmoid*, bipolar *sigmoid*), learning rates (0.01, 0.1, 0.5), and epochs (1000, 1500, 2000) were tested to obtain the best configuration. The optimal results were achieved with the 27-54-54-1 architecture using the *ReLU* activation function, a learning rate of 0.5, and 2000 epochs. This configuration produced prediction performance with a Mean Squared Error (MSE) of 0.000542, R-squared (*R*<sup>2</sup>) of 0.972010, and a Mean Absolute Percentage Error (MAPE) of 1.26%. These findings demonstrate that the Backpropagation Artificial Neural Network can be effectively applied to predict the purity level of honey.

**Keywords** - *Artificial Neural Network, Backpropagation, Prediction, Honey Purity*

## 1. PENDAHULUAN

Madu merupakan produk alami hasil olahan nektar oleh lebah yang memiliki nilai ekonomi serta manfaat kesehatan yang tinggi. Kandungan utama madu meliputi gula seperti fruktosa, glukosa, dan sukrosa, disertai dengan berbagai senyawa bioaktif seperti asam organik, enzim, dan antioksidan [1]. Komposisi yang kompleks menjadikan madu tidak hanya sebagai sumber energi, tetapi juga sebagai bahan pangan fungsional yang memiliki aktivitas bioaktif penting [2]. Nilai gizi dan manfaat yang tinggi menyebabkan permintaan madu di pasaran terus meningkat. Namun, kapasitas produksi madu di Indonesia masih relatif rendah, yakni sekitar 2.000 ton per tahun, sedangkan kebutuhan mencapai 7.500 ton per tahun [3]. Kondisi tersebut mendorong terjadinya praktik pemalsuan. Sejumlah penelitian menunjukkan bahwa pemalsuan madu biasanya dilakukan dengan mencampurkan larutan gula, sirup glukosa-fruktosa, atau bahan tambahan lain yang dapat memengaruhi parameter fisikokimia seperti kadar air, pH, dan aktivitas enzim diastase [4]. Oleh karena itu, pengujian kemurnian madu menjadi aspek penting dalam menjamin kualitas dan keamanan produk yang beredar di pasaran.

Kualitas madu sangat dipengaruhi tingkat kemurniannya. Standar Nasional Indonesia (SNI 8664:2018) menetapkan sejumlah parameter fisikokimia yang harus dipenuhi, seperti kadar air, pH, kadar gula pereduksi, aktivitas diastase, serta kadar hidroksimetilfurfural (HMF) [5]. Parameter-parameter ini menjadi indikator penting untuk mengetahui penurunan mutu akibat proses pascapanen yang tidak tepat [6]. Berdasarkan penelitian [7], pengujian madu dapat dilakukan menggunakan dua pendekatan, yaitu metode konvensional dan metode kimia. Metode konvensional umumnya dilakukan secara visual untuk menilai karakteristik fisik madu, namun hasilnya bersifat subjektif dan belum mampu memberikan kepastian terhadap keaslian produk. Sementara itu, metode kimia seperti pengujian kadar abu, padatan tak larut dalam air, dan keasaman mampu memberikan hasil yang lebih akurat, tetapi memerlukan peralatan laboratorium khusus serta proses analisis yang relatif lama dan mahal. Untuk mengatasi keterbatasan metode konvensional dan kimia, pendekatan komputasional berbasis kecerdasan buatan mulai diterapkan dalam analisis mutu pangan.

Seiring dengan kemajuan teknologi informasi dan kecerdasan buatan (*Artificial Intelligence/AI*), pengolahan data secara komputasional semakin berkembang dan dapat dimanfaatkan untuk memprediksi berbagai parameter kualitas bahan pangan. Hal ini sejalan dengan penerapan AI dalam sektor pertanian dan industri pangan, yang telah terbukti meningkatkan efisiensi produksi dan distribusi, serta memastikan keamanan dan keberlanjutan sistem pangan di Indonesia [8]. Salah satu metode yang banyak digunakan adalah *Artificial Neural Network* (ANN), yang memiliki kemampuan untuk mempelajari hubungan nonlinier antara variabel *input* dan *output* melalui proses pembelajaran berulang [9]. Kemampuan ANN dalam mengidentifikasi pola data yang kompleks menjadikannya dapat diterapkan pada berbagai kasus prediksi [10]. Di antara beberapa model ANN, algoritma *Backpropagation Neural Network* (BPNN) dikenal memiliki kemampuan yang baik dalam menangani permasalahan prediksi kuantitatif dengan tingkat kesalahan yang rendah [11].

Penelitian terdahulu mengenai penerapan *Artificial Neural Network* (ANN) telah banyak dilakukan pada berbagai bidang. Penelitian [12] mengembangkan model klasifikasi kualitas madu dengan memanfaatkan parameter warna, kecerahan, dan pH, yang terbukti efektif dengan tingkat akurasi tinggi. Namun, penelitian tersebut lebih menekankan pada klasifikasi, sedangkan penelitian ini diarahkan pada prediksi tingkat kemurnian madu dalam bentuk numerik. Penelitian yang dilakukan oleh [13] menunjukkan kemampuan ANN *multilayer* dalam memprediksi kuat tekan beton dengan tingkat *error* yang relatif rendah. Walaupun objek yang dianalisis berbeda, penelitian tersebut menegaskan potensi ANN dalam menghasilkan prediksi kuantitatif. Selanjutnya, penelitian [14] membandingkan performa BPNN dan RNN dalam memprediksi curah hujan serta kecepatan angin, dan hasilnya menunjukkan bahwa ANN tetap mampu memberikan hasil prediksi yang akurat pada permasalahan yang berbeda.

Berdasarkan hasil penelitian sebelumnya, ANN terbukti efektif untuk berbagai permasalahan prediksi, namun penerapan secara spesifik pada prediksi tingkat kemurnian madu berdasarkan parameter fisikokimia masih sangat terbatas. Selain itu, sebagian besar penelitian terdahulu belum meninjau secara sistematis pengaruh variasi *hyperparameter* seperti jumlah *neuron*, fungsi aktivasi, dan *learning rate* terhadap performa model prediksi. Celaah penelitian ini menjadi dasar pengembangan penelitian yang dilakukan.

Tujuan dari penelitian ini adalah untuk membangun model *Backpropagation Artificial Neural Network* (ANN) yang mampu memprediksi tingkat kemurnian madu secara kuantitatif berdasarkan parameter fisikokimia. Kebaruan penelitian ini terletak pada penerapan dua lapisan tersembunyi (*hidden layer*) dengan variasi fungsi aktivasi berbeda untuk meningkatkan performa prediksi serta analisis pengaruh pengaturan *hyperparameter* terhadap hasil yang diperoleh. Pendekatan ini diharapkan dapat memberikan kontribusi terhadap pengembangan metode komputasi cerdas dalam analisis mutu pangan, khususnya dalam prediksi kemurnian madu secara efisien dan akurat.

## 2. METODE PENELITIAN

Metodologi penelitian ini mencakup sejumlah tahapan yang dilakukan, mulai dari pengumpulan data hingga analisis hasil, dengan tujuan untuk memberikan gambaran menyeluruh terhadap proses penelitian.

### 2.1. Pengumpulan data

Penelitian ini menggunakan *dataset* yang diperoleh dari *website* Kaggle dengan nama *Predict Purity and Price of Honey*. *Dataset* tersebut berisi informasi mengenai kemurnian madu serta faktor-faktor yang memengaruhi kualitasnya. *Dataset* terdiri atas 247,903 data dan 11 atribut, sebagaimana ditunjukkan pada tabel 1. Dari 11 atribut tersebut, 9 atribut yaitu CS, Density, WC, pH, EC, F, G, *Pollen\_analysis*, dan *Viscosity* digunakan sebagai variabel *input*, sedangkan atribut *Purity* dijadikan sebagai variabel target prediksi.

Tabel 1. *Dataset* Kemurnian Madu

CS	Density	WC	pH	EC	F	G	Pollen_analysis	Viscosity	Purity	Price
2,8	1,75	23	6,3	0,8	39	33,6	Blueberry	4844,5	0,68	645,2
9,5	1,82	17,5	7,2	0,7	38,2	34,4	Alfalfa	6689,02	0,89	385,9
4,6	1,84	23,7	7,3	0,8	27,5	34,4	Chestnut	6883,6	0,66	639,6
1,8	1,4	16,6	4	0,8	31,5	28,2	Blueberry	7167,56	1,00	946,5
6,1	1,25	19,6	4,8	0,9	29,7	42,5	Alfalfa	5125,44	1,00	432,6

### 2.2. Pengolahan data

#### 2.2.1. Data Understanding

Pada tahap ini peneliti mengumpulkan informasi penting dalam *dataset*, memahami struktur data, serta mengidentifikasi keterkaitan antar variabel. Atribut yang tidak relevan, seperti Price, dihapus karena tidak berkontribusi terhadap tujuan penelitian.

#### 2.2.2. Exploratory Data Analysis

Analisis awal dilakukan untuk mendeteksi potensi masalah, seperti data yang hilang atau tidak lengkap. Jika terdapat *missing value*, penanganan dilakukan dengan mengganti data yang hilang menggunakan rata-rata tiap atribut.

### 2.2.3. Transformasi Data

Atribut kategori Pollen Analysis diubah menggunakan metode *One-Hot Encoding* (OHE). Atribut ini memiliki 19 kategori, yaitu: Acacia, Alfalfa, Avocado, Blueberry, Borage, Buckwheat, Chestnut, Clover, Eucalyptus, Heather, Lavender, Manuka, Orange Blossom, Rosemary, Sage, Sunflower, Thyme, Tupelo, dan Wildflower. Setelah transformasi, atribut Pollen Analysis yang semula berupa satu kolom digantikan menjadi 19 kolom biner, sehingga jumlah fitur *input* meningkat dari 9 atribut awal menjadi  $8 + 19 = 27$  fitur.

### 2.2.4. Normalisasi Data

Normalisasi dilakukan untuk menyeragamkan skala antar atribut numerik. Metode yang digunakan adalah *Min-Max Normalization*, dengan rumus:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Keterangan:

$X'$  = hasil perhitungan normalisasi

$X$  = nilai asli dari suatu atribut

$X_{min}, X_{max}$  = nilai minimum dan maksimum pada atribut

Normalisasi hanya diterapkan pada atribut numerik (CS, Density, WC, pH, EC, F, G, dan Viscosity), sedangkan hasil OHE tidak dinormalisasi karena sudah berupa bilangan biner (0 dan 1). Untuk mencegah *data leakage*, parameter normalisasi berupa nilai minimum dan maksimum dihitung dari data latih, kemudian parameter tersebut digunakan untuk menormalisasi baik data latih maupun data uji.

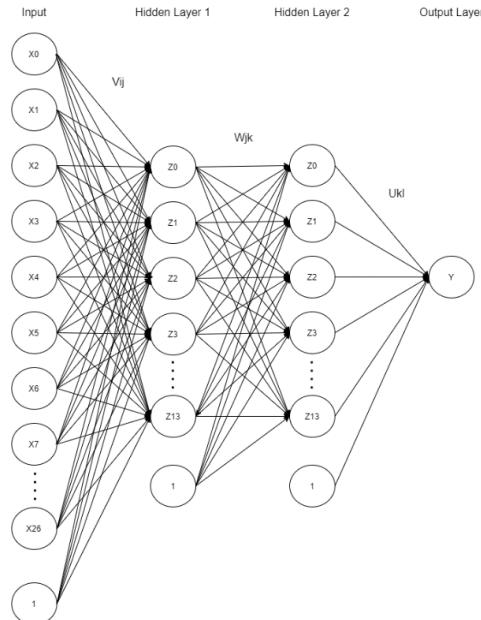
### 2.2.5. Pembagian Data

Dataset dibagi menjadi data latih dan data uji menggunakan rasio 70:30 dan 80:20. Pembagian dilakukan secara acak dengan penetapan *random seed* = 42 agar hasil pembagian data tetap konsisten meskipun dilakukan secara acak. Skema validasi yang digunakan dalam penelitian ini adalah *Hold-out Validation* dengan evaluasi performa model dilakukan pada kedua rasio pembagian data tersebut.

## 2.3. Artificial Neural Network (ANN)

*Artificial Neural Network* atau sering disebut juga dengan Jaringan Saraf Tiruan, merupakan salah satu bentuk kecerdasan buatan atau pemrosesan data yang bertindak seperti sistem biologis, khususnya pada sel otak manusia. Otak mengandung sel-sel saraf dan merupakan bagian terpenting dalam pemrosesan informasi. Bagian ini disebut neuron yang saling berhubungan dan bekerja sama untuk memecahkan suatu masalah seperti masalah klasifikasi atau prediksi [15].

## 2.4. Backpropagation Neural Network



Gambar 1. Arsitektur Backpropagation Neural Network

*Backpropagation* merupakan algoritma pembelajaran terawasi yang digunakan oleh *perceptron multilayer* untuk mengubah bobot yang terkait dengan neuron di lapisan tersembunyi [16]. *Backpropagation* bekerja melalui proses secara berulang dengan menggunakan sekumpulan data sampel (data pelatihan), kemudian membandingkan nilai prediksi dari jaringan dengan setiap data sampel. Pada setiap proses, bobot koneksi dalam jaringan diubah untuk meminimalkan nilai *error* antara nilai prediksi jaringan dengan nilai sebenarnya. Penyesuaian koneksi jaringan saraf dilakukan dalam arah mundur, dimulai dari lapisan keluaran kemudian diteruskan ke lapisan-lapisan tersembunyi, sehingga metode ini disebut dengan propagasi balik [17]. Adapun arsitektur dan *hyperparameter* yang digunakan dalam penelitian ini adalah sebagai berikut:

#### 2.4.1. Neuron hidden layer

Penelitian ini menggunakan tiga variasi jumlah neuron pada *hidden layer*, yaitu 14-14, 27-27, dan 54-54. Pemilihan konfigurasi ini bertujuan untuk membandingkan performa model dengan jumlah neuron yang lebih sedikit, seimbang, maupun lebih banyak dibandingkan jumlah variabel *input*. Penambahan jumlah *hidden layer* dapat meningkatkan akurasi model, dan peningkatan jumlah neuron pada tiap *hidden layer* juga berpengaruh dalam menurunkan *error* [18].

#### 2.4.2. Fungsi Aktivasi

Fungsi aktivasi yang diuji pada penelitian ini meliputi ReLU, *sigmoid* biner, dan *sigmoid* bipolar. Variasi ini dipilih untuk melihat bagaimana perbedaan karakteristik fungsi aktivasi memengaruhi hasil prediksi. Fungsi aktivasi berperan penting dalam mengatur kekuatan sinyal yang diteruskan antar neuron sehingga berpengaruh langsung pada akurasi model [19]. Fungsi aktivasi yang digunakan pada penelitian ini adalah fungsi *Rectified Linear Units* atau ReLU, *sigmoid* biner dan *sigmoid* bipolar.

- Fungsi aktivasi ReLU adalah fungsi yang menghasilkan *output* nol ketika *input* bernilai negatif, sedangkan jika *input* bernilai positif, *output*-nya akan sama dengan nilai *input* tersebut [20]. Fungsi ReLU dirumuskan pada persamaan berikut:

$$f(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (2)$$

$$f'(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (3)$$

Keterangan:

$x$  = nilai data *input*

$f(x)$  = hasil *output* fungsi ReLU

$f'(x)$  = hasil turunan fungsi ReLU

- b Fungsi aktivasi *sigmoid* biner adalah fungsi yang mengubah *output* yang diperoleh menjadi rentang antara 0 hingga 1 [21]. Fungsi *sigmoid* biner dirumuskan pada persamaan berikut:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

$$f'(x) = \frac{e^{-x}}{(1 + e^{-x})^2} \quad (5)$$

Keterangan:

$x$  = nilai data *input*

$f(x)$  = hasil *output* fungsi *sigmoid* biner dalam rentang 0 hingga 1

$f'(x)$  = hasil turunan fungsi *sigmoid* biner

$e$  = bilangan eksponensial ( $\approx 2,71828$ )

- c Fungsi aktivasi *sigmoid* bipolar merupakan fungsi yang menghasilkan keluaran (*output*) dalam rentang nilai antara -1 hingga 1 [22]. Fungsi *sigmoid* bipolar dirumuskan pada persamaan berikut:

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (6)$$

$$f'(x) = \frac{1 - [f(x)]^2}{2} \quad (7)$$

Keterangan:

$x$  = nilai data *input*

$f(x)$  = hasil *output* fungsi *sigmoid* bipolar dalam rentang -1 hingga 1

$f'(x)$  = hasil turunan fungsi *sigmoid* bipolar

$e$  = bilangan eksponensial ( $\approx 2,71828$ )

#### 2.4.3. Learning rate

Untuk menguji pengaruh nilai *learning rate* terhadap kinerja model, penelitian ini menggunakan beberapa variasi, yaitu 0,01, 0,1 dan 0,5. Pemilihan nilai tersebut dimaksudkan untuk melihat perbedaan performa antara *learning rate* kecil, sedang, dan relatif besar. *Learning rate* sangat menentukan kualitas pembelajaran jaringan, nilai yang terlalu kecil membuat proses konvergensi sangat lambat, sedangkan nilai yang terlalu besar berpotensi menyebabkan model tidak stabil karena pembaruan bobot melampaui titik minimum *error* [23].

#### 2.4.4. Max Epoch

Variasi jumlah *epoch* yang digunakan dalam penelitian ini adalah 1000, 1500, dan 2000. *Epoch* merupakan jumlah iterasi penuh data pelatihan yang melalui proses *feedforward*, *backpropagation*, hingga pembaruan bobot. Jumlah *epoch* yang rendah cenderung menyebabkan model mengalami *overfitting*, sedangkan penggunaan *epoch* yang terlalu tinggi berpotensi menimbulkan *underfitting* [24].

#### 2.5. Evaluasi Model

Evaluasi model merupakan proses untuk mengukur performa model yang telah dihasilkan pada proses *training* dan *testing* [25]. Proses ini bertujuan untuk menentukan seberapa efektif model dalam menghasilkan prediksi yang akurat. Terdapat berbagai metode untuk mengevaluasi model diantaranya:

##### 2.5.1. Mean Squared Error (MSE)

MSE merupakan metrik yang digunakan untuk mengukur kinerja model regresi dalam memprediksi nilai kontinu. MSE dihitung dengan cara mengukur selisih antara nilai sebenarnya dan nilai prediksi pada setiap sampel data, kemudian mengkuadratkan setiap selisihnya agar semua bernilai positif. Selanjutnya, rata-rata dari kuadrat selisih dihitung [26]. Rumus *Mean Squared Error* ditunjukkan pada persamaan berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_{i'})^2 \quad (8)$$

Keterangan:

n = jumlah total sampel data.

$Y_i$  = nilai target aktual untuk sampel ke-i

$Y_{i'}$  = nilai prediksi dari model untuk sampel ke-i

#### 2.5.2. *R-squared (R<sup>2</sup>)*

$R^2$  merupakan metrik yang digunakan untuk mengukur kebaikan model (*goodness of fit*) dalam regresi, metrik ini memberikan proporsi atau persentase variasi total pada variabel terikat yang dijelaskan oleh variabel bebas.  $R^2$  dihitung melalui beberapa tahap, yang pertama adalah menghitung nilai rata-rata dari data yang digunakan. Kemudian, dihitung jumlah kuadrat dan jumlah kuadrat residual. Pada tahap terakhir, nilai koefisien determinasi dihitung [27]. Rumus *R-squared* ditunjukkan pada persamaan berikut:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - Y_{i'})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (9)$$

Keterangan:

n = jumlah total sampel data

$Y_i$  = nilai target aktual untuk sampel ke-i

$Y_{i'}$  = nilai prediksi dari model untuk sampel ke-i

$\bar{Y}$  = rata-rata nilai target aktual

#### 2.5.3. *Mean Absolute Percentage Error (MAPE)*

MAPE merupakan metrik yang digunakan untuk mengukur tingkat keakuratan prediksi pada suatu model. MAPE dihitung dengan mengukur rata-rata kesalahan dalam bentuk persentase mutlak antara nilai aktual dan nilai prediksi. MAPE memberikan informasi tentang sejauh mana kesalahan prediksi dibandingkan dengan nilai aktual data [20]. Rumus *Mean Absolute Percentage Error* ditunjukkan pada persamaan berikut:

$$MAPE = \sum_{i=1}^n \left| \frac{y_i - y_{i'}}{y_i} \right| \times 100\% \quad (10)$$

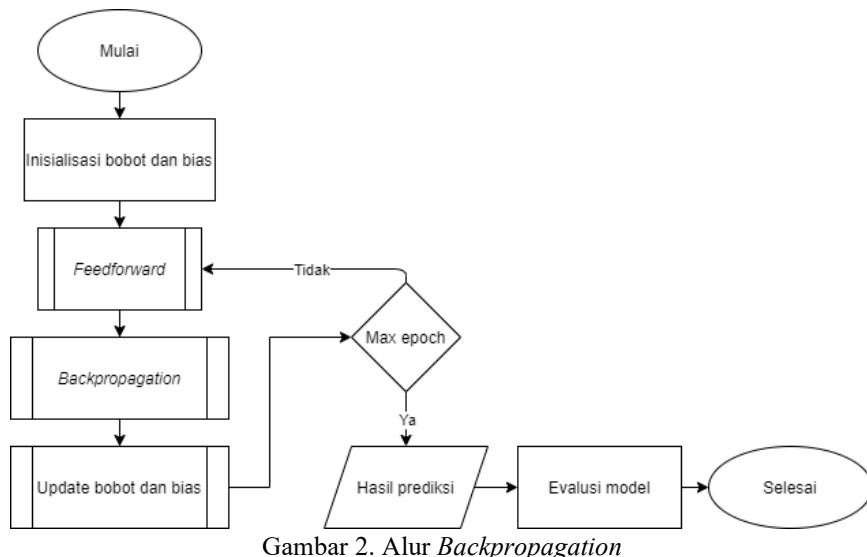
Keterangan:

n = jumlah total sampel data.

$Y_i$  = nilai target aktual untuk sampel ke-i

$Y_{i'}$  = nilai prediksi dari model untuk sampel ke-i

#### 2.6. *Flowchart Algoritma*



Proses *Backpropagation* dimulai dengan inisialisasi bobot dan bias secara acak. Selanjutnya dilakukan tahap *feedforward* untuk menghitung keluaran pada *hidden layer* dan *output layer*, kemudian *backpropagation* menghitung *error* dan *delta* bobot untuk memperbarui bobot dan bias. Pada setiap iterasi dilakukan pengecekan apakah jumlah *epoch* telah mencapai maksimum. Jika jumlah *epoch* belum mencapai maksimum, proses kembali ke tahap *feedforward* untuk iterasi berikutnya. Setelah maksimum *epoch* tercapai, proses berhenti dan dihasilkan *output* berupa prediksi kemurnian madu, kemudian model dievaluasi untuk menilai performa prediksi yang dihasilkan.

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Pengujian dan Analisis

Pada tahap pengujian dan analisis, dilakukan evaluasi terhadap model prediksi yang dibangun menggunakan algoritma *Backpropagation Neural Network*. Pengujian dilakukan dengan pembagian data pelatihan dan data pengujian menggunakan rasio 80:20 dan 70:30. Model yang diuji memiliki arsitektur jaringan 27-14-14-1, 27-27-27-1, dan 27-54-54-1. Angka 27 menunjukkan jumlah neuron pada *input layer*, dua *hidden layer* masing-masing terdiri dari 14, 27, dan 54 neuron, serta 1 neuron pada *output layer* yang menghasilkan nilai prediksi. Dalam proses pelatihan, beberapa kombinasi *hyperparameter* diuji untuk memperoleh performa terbaik. Fungsi aktivasi yang digunakan meliputi ReLU, sigmoid biner, dan sigmoid bipolar. Jumlah *epoch* yang diuji adalah 1000, 1500, dan 2000, sedangkan nilai *learning rate* yang diuji adalah 0,01, 0,1, dan 0,5. Pengujian dilakukan pada beberapa skenario, yaitu:

##### 3.1.1. Pengujian Perbandingan Data Pada Rasio 70:30 dan 80:20.

Pengujian pertama dilakukan pada proporsi data 70:30 menggunakan *hyperparameter* yang telah ditentukan, diperoleh akurasi tertinggi yang disajikan pada tabel 2.

Tabel 2. Pengujian Rasio Data 70:30

Fungsi Aktivasi	Arsitektur	Epoch	Learning Rate	MSE	R <sup>2</sup>	MAPE
ReLU	27-54-54-1	2000	0,5	0,000542	0,972010	1,26%

Pada pengujian dengan rasio data 70:30, model terbaik diperoleh menggunakan fungsi aktivasi ReLU dengan arsitektur 27-54-54-1, jumlah *epoch* sebanyak 2000, dan *learning rate* 0,5. Hasil yang

dicapai menunjukkan *error* prediksi yang sangat rendah dengan nilai MSE sebesar 0,000542, serta menunjukkan performa prediksi yang tinggi dengan nilai R<sup>2</sup> sebesar 0,972010. Selain itu, nilai MAPE hanya 1,26%, yang menandakan bahwa model mampu memberikan prediksi yang sangat mendekati data aktual.

Pengujian berikutnya dilakukan dengan proporsi data 80:20. Hasil pengujian disajikan pada tabel 3.

Tabel 3. Pengujian Rasio Data 80:20

Fungsi Aktivasi	Arsitektur	Epoch	Learning Rate	MSE	R <sup>2</sup>	MAPE
ReLU	27-54-54-1	1500	0,5	0,000539	0,972110	1,42%

Pengujian pada rasio data 80:20, model terbaik menggunakan konfigurasi yang sama, namun dengan 1500 *epoch*. Nilai MSE yang diperoleh adalah 0,000539, R<sup>2</sup> sebesar 0,972110, dan MAPE sebesar 1,42%. Meskipun MSE terlihat sedikit lebih kecil, nilai MAPE yang lebih tinggi mengindikasikan bahwa hasil prediksi tidak seakurat pada rasio 70:30. Dengan demikian, rasio 70:30 dapat dikatakan lebih optimal karena mampu memberikan keseimbangan terbaik antara *error* yang rendah dan akurasi yang tinggi.

### 3.1.2. Perbandingan Fungsi Aktivasi

Pengujian kedua dilakukan dengan menggunakan tiga fungsi aktivasi yang berbeda, yaitu ReLU, Sigmoid Biner, dan Sigmoid Bipolar, pada arsitektur jaringan 27-54-54-1 dengan jumlah *epoch* sebanyak 2000 dan nilai *learning rate* 0,5. Hasil pengujian disajikan pada tabel 4.

Tabel 4. Perbandingan Fungsi Aktivasi

Fungsi Aktivasi	Arsitektur	Epoch	Learning Rate	MSE	R <sup>2</sup>	MAPE
ReLU	27-54-54-1	2000	0,5	0,000542	0,972010	1,26%
Sigmoid Biner	27-54-54-1	2000	0,5	0,002097	0,891802	3,99%
Sigmoid Bipolar	27-54-54-1	2000	0,5	0,000878	0,954715	2,20%

Pengujian dengan tiga fungsi aktivasi menunjukkan perbedaan performa yang cukup signifikan. ReLU memberikan hasil yang paling unggul, dengan MSE sebesar 0,000542, R<sup>2</sup> mencapai 0,972010, dan MAPE hanya 1,26%. Sebaliknya, fungsi aktivasi Sigmoid Biner menghasilkan performa yang jauh lebih rendah, dengan MSE sebesar 0,002097, R<sup>2</sup> hanya 0,891802, dan MAPE meningkat hingga 3,99%. Adapun Sigmoid bipolar memberikan hasil yang lebih baik daripada sigmoid biner, dengan MSE sebesar 0,000878, R<sup>2</sup> sebesar 0,954715, dan MAPE sebesar 2,20%, terlihat bahwa meskipun cukup stabil, fungsi ini tetap menghasilkan *error* yang lebih tinggi dibandingkan ReLU. Oleh karena itu, ReLU dapat dipastikan sebagai fungsi aktivasi terbaik pada penelitian ini.

### 3.1.3. Perbandingan Arsitektur

Pengujian ketiga dilakukan dengan menggunakan tiga arsitektur yang berbeda, yaitu 27-54-54-1, 27-27-27-1 dan 27-14-14-1, dengan fungsi aktivasi ReLU, jumlah *epoch* sebanyak 2000, dan nilai *learning rate* 0,5. Hasil pengujian disajikan pada tabel 5.

Tabel 5. Perbandingan Arsitektur

Arsitektur	Fungsi Aktivasi	Epoch	Learning Rate	MSE	R <sup>2</sup>	MAPE
27-54-54-1	ReLU	2000	0,5	0,000542	0,972010	1,26%

27-27-27-1	ReLU	2000	0,5	0,000590	0,969563	1,54%
27-14-14-1	ReLU	2000	0,5	0,000925	0,952279	2,62%

Pengujian terhadap tiga arsitektur yang berbeda memperlihatkan bahwa jumlah neuron pada *hidden layer* sangat memengaruhi performa model. Arsitektur 27-54-54-1 terbukti paling unggul, dengan MSE terkecil sebesar 0,000542, R<sup>2</sup> tertinggi sebesar 0,972010, serta MAPE terendah sebesar 1,26%. Arsitektur 27-27-27-1 menghasilkan performa yang cukup baik, dengan MSE sebesar 0,000590, R<sup>2</sup> sebesar 0,969563, dan MAPE sebesar 1,54%. Adapun arsitektur 27-14-14-1 memiliki performa paling rendah, ditandai dengan MSE sebesar 0,000925, R<sup>2</sup> sebesar 0,952279, dan MAPE sebesar 2,62%. Dengan demikian, dapat disimpulkan bahwa arsitektur dengan jumlah neuron yang lebih besar pada *hidden layer*, seperti 27-54-54-1, mampu memberikan hasil terbaik dalam penelitian ini.

### 3.2. Pembahasan

Berdasarkan pengujian rasio data, terlihat bahwa model dengan proporsi data latih 70% dan data uji 30% memberikan hasil yang paling optimal. Model ini mampu menangkap pola data secara efektif, meskipun jumlah data latih relatif lebih sedikit. Nilai kesalahan prediksi rendah, tercermin dari angka angka kinerja yang unggul dibandingkan rasio 80:20. Sementara itu, rasio 80:20, meskipun menyediakan lebih banyak data latih, justru menunjukkan performa yang sedikit menurun. Hal ini menunjukkan bahwa jumlah data uji yang lebih kecil kurang mampu mencerminkan variasi data secara menyeluruh, sehingga model tidak sepenuhnya optimal. Dari sini dapat disimpulkan bahwa rasio 70:30 memberikan keseimbangan terbaik antara kemampuan belajar model dan representasi data uji.

Pengujian terhadap fungsi aktivasi menunjukkan adanya pengaruh yang signifikan terhadap stabilitas serta kecepatan proses pembelajaran. Fungsi ReLU terbukti memberikan performa terbaik, karena model lebih cepat mencapai konvergensi dan mampu meminimalkan *error* secara efektif. Sebaliknya, fungsi *sigmoid* biner menghasilkan proses pembelajaran yang lebih lambat dengan tingkat *error* lebih besar akibat gradien yang cenderung mengecil pada nilai *output* ekstrem, sehingga memperlambat pembaruan bobot. Sementara itu, *sigmoid* bipolar memberikan hasil yang lebih baik dibandingkan *sigmoid* biner, namun masih berada di bawah performa ReLU. Dengan demikian, ReLU dapat dianggap sebagai pilihan paling ideal karena stabil, cepat, dan mampu memodelkan variasi data secara optimal.

Jumlah neuron pada *hidden layer* juga memengaruhi kemampuan model dalam mempelajari pola data. Arsitektur dengan jumlah neuron lebih banyak pada setiap *hidden layer*, seperti 27-54-54-1, mampu menangkap variasi data yang lebih kompleks dan menghasilkan performa terbaik. Arsitektur menengah, 27-27-27-1, cukup stabil namun kurang optimal dibanding arsitektur terbesar. Sementara itu, arsitektur 27-14-14-1 dengan neuron lebih sedikit terbukti kurang mampu menangkap karakteristik data secara mendalam, sehingga performanya paling rendah. Hal ini menunjukkan bahwa peningkatan jumlah neuron dapat meningkatkan kemampuan model untuk mempelajari pola data yang kompleks.

Faktor lain yang memengaruhi performa adalah *learning rate* dan jumlah *epoch*. *Learning rate* 0,5 terbukti cukup efektif dalam mempercepat pembaruan bobot tanpa mengurangi konsistensi. Jumlah *epoch* yang lebih tinggi memberikan kesempatan bagi jaringan untuk menyesuaikan bobot hingga kondisi optimal tercapai, sehingga hasil prediksi lebih akurat. Secara keseluruhan, kombinasi rasio data 70:30, fungsi aktivasi ReLU, arsitektur 27-54-54-1, *learning rate* 0,5, dan 2000 *epoch* menghasilkan performa terbaik. Model ini berhasil meminimalkan *error*, sehingga menunjukkan kemampuan yang sangat baik dalam mempelajari karakteristik data.

## 4. KESIMPULAN

Berdasarkan tahapan pengujian yang telah dilakukan dalam memprediksi tingkat kemurnian madu menggunakan algoritma *Backpropagation Artificial Neural Network*, dapat disimpulkan bahwa pemilihan *hyperparameter* memiliki peran penting dalam menentukan kinerja model. Hasil terbaik

ditunjukkan oleh arsitektur jaringan 27-54-54-1 dengan fungsi aktivasi ReLU, *learning rate* 0,5, dan jumlah *epoch* sebanyak 2000. Pada konfigurasi tersebut, model mampu menghasilkan tingkat kesalahan yang rendah (MSE 0,000542), R<sup>2</sup> sebesar 0,972010, serta MAPE sebesar 1,26%. Hal ini membuktikan bahwa metode *Backpropagation Artificial Neural Network* dapat digunakan secara efektif dalam memprediksi tingkat kemurnian madu. Untuk penelitian selanjutnya, disarankan agar dilakukan perbandingan performa antara *Backpropagation Artificial Neural Network* dengan algoritma *machine learning* lainnya guna mengetahui apakah terdapat metode yang lebih tepat dalam memprediksi tingkat kemurnian madu.

## DAFTAR PUSTAKA

- [1] I. Y. Wardhani *et al.*, “Analisis Komparasi Kualitas Madu di Kudus Raya Pantura Jawa Tengah,” 2023.
- [2] P. L. Cahyaningrum, “Aktivitas Antioksidan Madu ternakan Dan Madu Kelengkeng Sebagai Pengobatan Alami,” *Widya Kesehatan*, vol. 1, no. 1, pp. 23–28, 2019.
- [3] S. R. Kamilya, A. Kadarsah, and T. Satriadi, “Produksi Madu dan Identifikasi Tumbuhan Sumber Pakan Lebah Kelulut Heterotrigona itama pada Meliponikultur di Desa Padang Panjang,” *Jurnal Natural Scientiae*, vol. 4, no. 2, 2024.
- [4] D. S. Ichsan, T. S. Hafidzah, S. B. Putri, S. V. Aurene, and I. Nurdin, “Deteksi Madu Palsu Dan Kualitas Madu Dengan Enzim Diastase,” *Poltekita : Jurnal Ilmu Kesehatan*, vol. 16, no. 3, pp. 278–283, Nov. 2022, doi: 10.33860/jik.v16i3.1685.
- [5] A. Pribadi and M. D. E. Wiratmoko, “Karakteristik Fisikokimia Madu Heterotrigona itama Asal Provinsi Riau,” *Wahana Forestra: Jurnal Kehutanan*, vol. 18, no. 2, pp. 105–120, 2023.
- [6] S. W. A. Suedy, A. A. Aisyah, S. Darmanti, and S. Parman, “Uji kualitas beberapa madu lokal di Semarang,” *Buletin Anatomi dan Fisiologi*, vol. 8, no. 2, pp. 161–168, 2023.
- [7] S. Prabowo, Y. Yuliani, Y. A. Prayitno, K. Lestari, and A. Kusesvara, “Penentuan karakteristik fisiko-kimia beberapa jenis madu menggunakan metode konvensional dan metode kimia,” *Journal of Tropical AgriFood*, vol. 1, no. 2, pp. 66–73, 2019.
- [8] R. F. N. Susilo and S. F. Athallah, “Penggunaan Artificial Intelligence (AI) dalam Membangun Sistem Pangan Berkelanjutan di Indonesia,” *Jurnal Imagine*, vol. 3, no. 2, pp. 104–116, 2023.
- [9] D. Galih Pradana, M. L. Alghifari, M. Farhan Juna, and S. Dwisiwi Palaguna, “Klasifikasi Penyakit Jantung Menggunakan Metode Artificial Neural Network,” *Indonesian Journal of Data and Science (IJODAS)*, vol. 3, no. 2, pp. 55–60, 2022.
- [10] A. Yani and E. Hegarini, “Analisa Kelayakan Kredit Menggunakan Artificial Neural Network dan Backpropagation (Studi Kasus German Credit Data): Array,” *Jurnal Ilmiah KOMPUTASI*, vol. 18, no. 4, pp. 385–390, 2019.
- [11] F. Rahmadani and A. M. Pardede, “JARINGAN SYARAF TIRUAN PREDIKSI JUMLAH PENGIRIMAN BARANG MENGGUNAKAN METODE BACKPROPAGATION ( STUDI KASUS: KANTOR POS BINJAI ),” *Jurnal Teknik Informatika Kaputama (JTIK)*, vol. 5, no. 1, 2021.
- [12] M. H. J. Alhamdani, D. Syauqy, and B. H. Prasetyo, “Sistem klasifikasi kualitas jenis-jenis madu berdasarkan warna, kecerahan, dan pH menggunakan metode JST backpropagation,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 6, pp. 2584–2590, 2022.
- [13] M. Afifuddin, D. Nafira, and F. Fachrurrazi, “Prediksi Kuat Tekan Beton Kinerja Tinggi Dengan Pemodelan Metode Artificial Neural Network (ANN),” *Jurnal Teknik Sipil*, vol. 10, no. 2, pp. 106–113, 2021.

- [14] D. A. H. Panggabean, F. M. Sihombing, and N. M. Aruan, "Prediksi Tinggi Curah Hujan Dan Kecepatan Angin Berdasarkan Data Cuaca Dengan Penerapan Algoritma Artificial Neural Network (ANN)," *PROSIDING SEMINASTIK4*, vol. 3, no. 1, pp. 1–7, 2021.
- [15] B. Tenggehi, I. Palupi, and E. B. Setiawan, "Prediksi perubahan kondisi uptrend dan downtrend pada pasar saham dengan menggunakan model artificial neural network ann," *eProceedings of Engineering*, vol. 9, no. 3, 2022.
- [16] M. Masruroh, "Perbandingan Metode Regresi Linear Dan Neural Network Backpropagation Dalam Prediksi Nilai Ujian Nasional Siswa Smp Menggunakan Software R," *Joutica*, vol. 5, no. 1, pp. 331–336, 2020.
- [17] P. Ariyadi, M. M. Effendi, and S. B. Raharjo, "Analisa Prediksi Harga Saham Blue Chip Lq45 Dengan Metode Data Mining Backpropagation Neural Network (Studi Kasus Di Bursa Efek Indonesia)," *Prosiding Sains Dan Teknologi*, vol. 1, no. 1, pp. 68–76, 2022.
- [18] S. Zahara, Y. N. Sukmaningtyas, R. M. Akbar, and M. Z. Abidin, "Pengaruh Jumlah Hidden Layer dan Neuron pada Model Multilayer Perceptron untuk Prediksi Emas," *Jurnal Ilmiah ILKOMINFO-Ilmu Komputer & Informatika*, vol. 8, no. 2, pp. 269–275, 2025.
- [19] N. Hikmah, S. Bahri, and I. Irwansyah, "Jaringan Syaraf Tiruan untuk Memprediksi Kadar Polutan Ozon di Kota Mataram," *Eigen Mathematics Journal*, pp. 70–85, 2022.
- [20] S. Soewignjo, Sediono, M. F. F. Mardianto, and E. Pusporani, "Prediksi Harga Saham Bank BCA (BBCA) Pasca Stock Split dengan Artificial Neural Network dengan Algoritma Backpropagation," *G-Tech: Jurnal Teknologi Terapan*, vol. 7, no. 4, pp. 1683–1693, Oct. 2023, doi: 10.33379/gtech.v7i4.3363.
- [21] W. Aryanti, "Penerapan artificial neural network dengan algoritma backpropagation untuk memprediksi harga saham," *Jurnal Riset Statistika*, pp. 107–118, 2023.
- [22] N. Liana and B. Sitepu, "Jaringan Saraf Tiruan Memprediksi Nilai Pemelajaran Siswa Dengan Metode Backpropagation ( Studi kasus : SMP Negeri 1 Salapian)," 2021.
- [23] S. Sunardi, "Pengaruh Nilai Hidden layer dan Learning rate Terhadap Kecepatan Pelatihan Jaringan Saraf Tiruan Backpropagation," *JIKO (Jurnal Informatika dan Komputer)*, vol. 6, no. 1, pp. 27–33, 2022.
- [24] S. G. Wardhana, M. Aldi, and I. R. Siregar, "Prediksi Kecepatan Gelombang Geser (Vs) Menggunakan Machine Learning di Sumur X," *JGE (Jurnal Geofisika Eksplorasi)*, vol. 8, no. 1, pp. 67–77, 2022.
- [25] I. D. Id, *Machine Learning: Teori, Studi Kasus dan Implementasi Menggunakan Python*, vol. 1. Unri Press, 2021.
- [26] I. Agustina, Y. Mulyani, T. Septiana, and M. Mardiana, "ANALISIS PENGEMBANGAN MODEL PREDIKSI KESUKSESAN KICKSTARTER MENGGUNAKAN ALGORITMA BACKPROPAGATION DAN RANDOM FOREST," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 10, no. 3, Aug. 2022, doi: 10.23960/jitet.v10i3.2742.
- [27] A. Cahyaningsih, N. Prasetya Putra, A. Pradika Ekoputro Pratama, and R. Ramadhani, "Journal of Informatics, Information System, Software Engineering and Applications Model Prediksi Jumlah Kumulatif Kasus COVID-19 di Indonesia Menggunakan Metode Neural Network," vol. 3, no. 1, pp. 76–083, 2020, doi: 10.20895/INISTA.V2I2.