

Implementasi Algoritma Jaringan Saraf Tiruan untuk Prediksi Hasil Panen Kakao Desa Minanga

Nahya Nur*, Sulfayanti, Andriani

Fakultas Teknik, Program Studi Informatika, Universitas Sulawesi Barat, Majene, Indonesia
Email: ¹*nahya.nur@unsulbar.ac.id, ²sulfayanti@unsulbar.ac.id, ³andryaniminanga001@email.com
Email Penulis Korespondensi: nahya.nur@unsulbar.ac.id
Submitted 13-04-2026; Accepted 30-04-2026; Published 30-04-2026

Abstrak

Produksi tanaman kakao di Desa Minanga menunjukkan fluktuasi yang tidak stabil, yang berdampak langsung pada ketidakpastian pendapatan petani dan kesulitan dalam perencanaan keuangan. Penelitian ini bertujuan untuk menerapkan algoritma Jaringan Saraf Tiruan (JST) metode Backpropagation sebagai instrumen prediksi hasil panen kakao. Data penelitian mencakup periode tahun 2019 hingga 2023 dengan total 2.980 data. Model prediksi dibangun menggunakan delapan kriteria utama, yaitu: luas lahan, jumlah tanaman, jenis bibit, jenis pupuk, serangan hama/penyakit, upaya penanggulangan, tingkat curah hujan, dan hasil panen sebelumnya. Pengujian dilakukan dengan menggunakan 3 skenario perbandingan data training dan data testing, yaitu 70:30, 80:20, dan 90:10. Variasi rasio ini digunakan untuk mengevaluasi stabilitas dan performa model dalam mengenali pola data. Selain itu, dilakukan pengujian komprehensif terhadap berbagai parameter arsitektur jaringan, learning rate, serta target error dengan memanfaatkan fungsi aktivasi sigmoid biner guna mengevaluasi stabilitas dan akurasi model dalam mengenali pola data yang kompleks. Hasil penelitian menunjukkan bahwa konfigurasi model terbaik dicapai pada rasio data 90:10 dengan arsitektur jaringan 7-6-1, learning rate 0,4, dan target error 0,0001. Model ini mampu menghasilkan tingkat akurasi sebesar 98,09% dengan nilai Mean Absolute Percentage Error (MAPE) sebesar 1,91%. Hasil penelitian menunjukkan bahwa JST Backpropagation terbukti efektif dan dapat digunakan sebagai metode alternatif untuk memprediksi hasil panen kakao di Desa Minanga.

Kata Kunci: Prediksi; Kakao; Jaringan Syaraf Tiruan; Kecerdasan Buatan; Backpropagation

Abstract

Cocoa production in Desa Minanga exhibits unstable fluctuations, which directly impact the uncertainty of farmers' incomes and pose challenges in financial planning. This study aims to apply the Backpropagation Artificial Neural Network (ANN) algorithm as an instrument for predicting cocoa yields. The research data covers the period from 2019 to 2023, comprising a total of 2,980 data points. The predictive model was developed using eight main criteria: land area, number of plants, seed type, fertilizer type, pest/disease attacks, mitigation efforts, rainfall levels, and previous harvest yields. Testing was conducted using three training-to-testing data ratio scenarios: 70:30, 80:20, and 90:10. These variations were used to evaluate the model's stability and performance in identifying data patterns. Furthermore, comprehensive testing was performed on various network architecture parameters, learning rates, and target errors, utilizing the binary sigmoid activation function to assess the model's stability and accuracy in recognizing complex data patterns. The research results indicate that the optimal model configuration was achieved with a 90:10 data ratio, a 7-6-1 network architecture, a learning rate of 0.4, and a target error of 0.0001. This model achieved an accuracy rate of 98.09% with a Mean Absolute Percentage Error (MAPE) of 1.91%. The findings demonstrate that the Backpropagation ANN is effective and can serve as an alternative method for predicting cocoa yields in Desa Minanga.

Keywords: Prediction; Cacao; Artificial Neural Network; Artificial Intelligence; Backpropagation

1. PENDAHULUAN

Kakao (*Theobroma cacao* L.) merupakan salah satu komoditas perkebunan paling strategis yang memberikan kontribusi signifikan terhadap perekonomian nasional Indonesia. Sebagai tanaman jangka panjang yang memiliki karakteristik unik karena dapat dipanen sepanjang tahun, kakao menempatkan Indonesia sebagai salah satu pemain utama dalam pasar global. Berdasarkan data The International Cocoa Organization (ICCO) tahun 2019, Indonesia merupakan pengekspor biji kakao terbesar yang berada pada peringkat keenam di dunia dengan produksi kakao sebesar 220.000 ton [1]. Hal ini menunjukkan bahwa komoditi kakao di masa depan akan terus berkembang dan meningkat. Untuk itu, bermacam-macam usaha sudah dilakukan Kementerian Pertanian melalui Direktorat Jenderal Perkebunan untuk meningkatkan hasil produksi tanaman kakao Indonesia [2].

Provinsi Sulawesi Barat, khususnya Kabupaten Mamasa, merupakan salah satu sentra produksi kakao yang memberikan kontribusi besar bagi pasokan kakao regional. Di wilayah ini, Desa Minanga di Kecamatan Bambang menonjol sebagai daerah dengan mayoritas penduduk yang berprofesi sebagai petani kakao. Budidaya kakao dilakoni petani sejak sekitar tahun 2003 dan merupakan mata pencaharian utama. Masalah utama yang dihadapi petani di Desa Minanga adalah ketidakstabilan hasil panen yang fluktuatif di setiap musimnya. Penurunan produksi secara drastis atau peningkatan yang tidak terduga sering kali terjadi tanpa adanya alat deteksi atau prediksi dini. Selain itu, perubahan hasil panen tiap musim seperti penurunan, maupun peningkatan yang tidak stabil yang berdampak pada ketidakpastian pendapatan [3]. Tanpa adanya gambaran mengenai berapa banyak hasil yang akan diperoleh di masa depan, petani kesulitan dalam melakukan perencanaan keuangan keluarga, manajemen anggaran untuk biaya perawatan tanaman, hingga pengadaan pupuk dan pestisida di musim tanam berikutnya. Ketimpangan informasi ini mempertegas urgensi adanya sebuah sistem prediksi yang mampu memberikan estimasi hasil panen secara presisi.

Pada bidang pertanian, upaya memprediksi hasil panen telah dilakukan dengan berbagai pendekatan metodologi. Prediksi hasil panen dapat digunakan untuk membantu petani dalam memberikan informasi hasil panen di masa yang

akan datang dengan menggunakan data dari periode sebelumnya. Prediksi dilakukan berdasarkan data-data masa lalu yang akan dianalisis dengan algoritma tertentu. Metode klasik masih relevan digunakan untuk memetakan tren produksi jangka panjang. Penelitian oleh Santika dan Novirani [1] menekankan penggunaan metode Time Series untuk menangkap pola historis produksi di wilayah spesifik seperti Kabupaten Batang. Sementara itu, Syafira dan Helma [2] memperluas pendekatan ini dengan menerapkan metode Autoregressive Distributed Lag (ARDL), yang mampu mengakomodasi hubungan jangka panjang dan keterlambatan (lag) antar variabel ekonomi atau produksi pada level nasional. Penelitian lainnya berupa sistem pendukung keputusan prediksi hasil panen kakao dengan metode Naïve Bayes berbasis Android. Penelitian ini menggunakan variabel yaitu pemilihan bibit, cuaca, penggunaan pupuk, kondisi tanah, dan perawatan kakao [4]. Di sisi lain, penggunaan regresi linear juga sering ditemukan dalam prediksi komoditas pangan lain seperti padi, dengan menerapkan algoritma Linear Regression untuk prediksi hasil panen tanaman tersebut. Variabel yang digunakan yaitu nama petani, luas lahan, jumlah bibit, jenis pupuk, takaran pupuk, hasil panen [5].

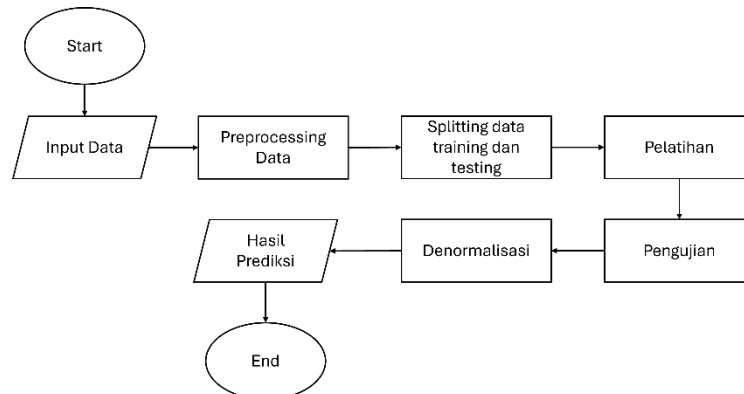
Sebagai solusi atas keterbatasan metode konvensional, Jaringan Saraf Tiruan (JST) atau Artificial Neural Network (ANN) muncul sebagai paradigma pemrograman informasi yang revolusioner. JST dirancang dengan mengadopsi struktur fungsional otak manusia [6], di mana jaringan terdiri dari neuron-neuron yang saling terhubung untuk memproses informasi secara paralel. Keunggulan utama JST terletak pada kemampuannya dalam melakukan pembelajaran mandiri untuk mengenali pola-pola tersembunyi dalam data besar. Dalam literatur data mining, JST telah terbukti sangat tangguh untuk tugas-tugas seperti klasifikasi, regresi, hingga peramalan deret waktu (time series forecasting) [7]. Salah satu algoritma paling populer dan efektif dalam JST adalah Backpropagation. Algoritma ini bekerja dengan cara meminimalkan error atau selisih antara output jaringan dengan target aktual melalui proses iterasi yang berkelanjutan. Dengan menyesuaikan bobot pada setiap lapisan tersembunyi (hidden layer), Backpropagation mampu menghasilkan model dengan tingkat akurasi yang cukup baik [8]. Penggunaan metode Backpropagation juga didukung oleh penelitian sebelumnya yang telah membandingkan antara metode regresi linear dan jaringan saraf tiruan dalam memprediksi harga makanan laut, dimana hasil penelitian tersebut memperlihatkan bahwa jaringan saraf tiruan menghasilkan akurasi yang lebih tinggi dibandingkan dengan regresi linear.

Meskipun penelitian terkait prediksi tanaman kakao sudah pernah dilakukan, sebagian besar masih berfokus pada klasifikasi atau regresi linier sederhana. Penggunaan Jaringan Saraf Tiruan (JST) dengan algoritma *Backpropagation* mengisi celah tersebut dengan menawarkan kemampuan adaptasi yang lebih tinggi terhadap kompleksitas parameter. Kebaruan dalam penelitian ini terletak pada integrasi delapan kriteria komprehensif sebagai parameter input, yang meliputi: luas lahan, jumlah tanaman kakao, jenis bibit, jenis pupuk, hama dan penyakit, penanggulangan hama dan penyakit, tingkat curah hujan, dan hasil panen sebelumnya. Dengan menggunakan dataset yang mencakup periode tahun 2019 hingga 2023 di Desa Minanga, penelitian ini tidak hanya sekadar melakukan peramalan angka, tetapi juga menganalisis bagaimana variabel-variabel biotik (hama/penyakit) dan abiotik (curah hujan/pupuk) berinteraksi dalam model JST. Berbeda dengan Naïve Bayes yang mengasumsikan independensi antar variabel, Backpropagation dalam penelitian ini akan memperlakukan seluruh kriteria sebagai satu kesatuan sistemik yang saling memengaruhi. Diharapkan, hasil dari penelitian ini dapat menjadi alternatif instrumen pengambilan keputusan bagi petani di Desa Minanga dalam mengelola anggaran perawatan dan merencanakan keuangan secara lebih stabil dan terukur di masa depan.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini terdiri atas beberapa tahapan mulai dari input data sampai dengan diperoleh hasil prediksi yang ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Gambar 1 menunjukkan tahapan penelitian yang dilakukan secara sistematis mulai dari persiapan data hingga perolehan hasil prediksi. Berikut adalah rincian dari setiap tahapan yang dilakukan:

- a. Pengumpulan dan Input Data: Tahap awal penelitian dimulai dengan memasukkan data mentah (*raw data*) yang akan digunakan sebagai basis analisis dalam model.

- b. Preprocessing Data: Data yang telah diinput kemudian melewati tahap preprocessing. Tahap ini sangat krusial untuk membersihkan data, menangani nilai yang hilang, atau melakukan normalisasi agar data berada dalam rentang yang sesuai untuk fungsi aktivasi sigmoid. Proses normalisasi ditunjukkan pada persamaan (1).

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

- c. Splitting Data Training dan Testing: Data yang telah siap kemudian dibagi menjadi dua bagian utama, yaitu data latih (*training data*) dan data uji (*testing data*). Pembagian ini bertujuan agar model dapat belajar dari satu set data dan kemudian diuji validitasnya menggunakan set data yang belum pernah dilihat sebelumnya.
- d. Pelatihan (*Training*): Pada tahap ini, model Jaringan Syaraf Tiruan menjalani proses pembelajaran menggunakan data latih. Di sinilah terjadi proses perambatan maju (*forward propagation*) dan perambatan balik (*backpropagation*) untuk menyesuaikan bobot berdasarkan *learning rate* hingga mencapai *target error* yang diinginkan.
- e. Pengujian (*Testing*): Setelah model dianggap optimal, dilakukan tahap pengujian menggunakan data uji. Tahap ini bertujuan untuk mengevaluasi sejauh mana kemampuan generalisasi model terhadap data baru.
- f. Denormalisasi: Karena pada tahap *preprocessing* data biasanya dinormalisasi ke rentang kecil (0-1), maka hasil keluaran jaringan perlu dikembalikan ke skala nilai aslinya melalui proses denormalisasi agar dapat diinterpretasikan secara nyata. Proses denormalisasi ditunjukkan pada persamaan (2).

$$y_{denorm} = y(x_{max} - x_{min}) + x_{min} \quad (2)$$

Dimana

x_{norm} : hasil normalisasi

y_{denorm} : hasil denormalisasi

x_{max} : nilai maksimal

x_{min} : nilai minimum

- g. Hasil Prediksi: Tahap akhir adalah perolehan nilai prediksi. Hasil ini merepresentasikan *output* akhir dari sistem yang kemudian dapat dianalisis tingkat akurasi sebelum penelitian dinyatakan selesai.

2.2 Backpropagation

Metode pelatihan Backpropagation pertama kali dirumuskan oleh Werbos dan dipopulerkan oleh Rumelhart dan McClelland untuk digunakan dalam JST. Metode Backpropagation adalah metode pelatihan Jaringan Saraf Tiruan yang digunakan untuk mencari bobot optimal pada Jaringan Saraf Tiruan dengan memiliki kemampuan untuk mentoleransi kesalahan atau meminimalkan error terhadap output yang dihasilkan jaringan sehingga dapat menghasilkan prediksi yang baik [9]. Dalam jaringan Backpropagation, terdapat pola input dan pola output yang diinginkan, dan ketika jaringan diberikan suatu pola, nilai bobot-bobot diubah agar dapat memperkecil perbedaan antara pola output dari jaringan dan pola output yang diinginkan. Proses pelatihan jaringan ini diulang sampai jaringan dapat mengenali semua pola output yang diinginkan [10]. Metode Backpropagation masuk dalam kategori Supervised Learning dan sering digunakan untuk proses prediksi, pengenalan dan peramalan, sehingga dengan penerapan metode Backpropagation dapat membantu dalam memprediksi hasil panen kakao pada Desa Minanga.

Adapun parameter yang ditentukan dalam Backpropagation diantaranya adalah *learning rate* dan fungsi aktivasi. Learning rate (α) adalah parameter yang berguna untuk menghitung nilai koreksi bobot dan bias, serta mempercepat iterasi. Semakin kecil nilai learning rate, semakin besar keakuratan, namun proses iterasi akan memerlukan waktu banyak [11]. Fungsi aktivasi merupakan hal penting karena berhubungan dalam tingkat keberhasilan yang diperoleh. Fungsi aktivasi digunakan untuk mengubah keluaran dari suatu neuron. Ada beberapa fungsi aktivasi yang sering digunakan yaitu sigmoid, ReLU (*Rectified Linear Unit*), dan *tangen hiperbolik* [12]. Fungsi aktivasi yang dipakai harus memenuhi beberapa syarat yaitu kontinyu, terdiferensial dengan mudah, dan merupakan fungsi yang tidak turun. Salah satu fungsi yang memenuhi dari ketiga syarat tersebut yaitu fungsi sigmoid biner [13]. Fungsi sigmoid biner digunakan pada Neural Network atau Jaringan Saraf Tiruan dilatih dengan menggunakan metode Backpropagation. Fungsi sigmoid biner memiliki nilai range 0 sampai 1, dengan persamaan (3) sebagai berikut :

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

Dimana :

$f(x)$: keluaran pada jaringan

x : hasil perkalian bobot dan input di tambah bias

e : bilangan eksponen

2.3 Evaluasi

Evaluasi dilakukan untuk mengukur seberapa efektif kinerja suatu sistem bekerja sesuai dengan tujuan penelitian, dalam hal ini terdapat beberapa metrik pengujian yang akan digunakan diantaranya MAPE dan akurasi.

- a. Mean Absolute Percentage Error (MAPE)

MAPE adalah ukuran tingkat akurasi untuk mengevaluasi keakuratan antara hasil prediksi dan data aktual. Penggunaan MAPE lebih fokus terhadap seberapa error atau kesalahan pada hasil prediksi dan nilai aktual. Semakin rendah nilai MAPE, maka kemampuan dari suatu model peramalan dikatakan baik [14]. Adapun persamaan MAPE ditunjukkan pada persamaan (4) sebagai berikut.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100 \% \quad (4)$$

Dimana :

MAPE : Mean Absolute Percentage Error

A_t : nilai aktual

F_t : nilai hasil prediksi

n : banyaknya data

b. Akurasi

Untuk menghitung akurasi terhadap prediksi yang dilakukan maka sebuah akurasi 100% dikurangi dengan nilai MAPE, yang menunjukkan semakin besar nilai akurasi maka semakin akurat hasil prediksi [9]. Adapun persamaan untuk menghitung nilai akurasi ditunjukkan pada persamaan (5).

$$Akurasi = 100\% - MAPE \quad (5)$$

3. HASIL DAN PEMBAHASAN

3.1 Data

Data penelitian yang digunakan untuk memprediksi hasil panen kakao menggunakan algoritma Jaringan Saraf Tiruan dengan metode Backpropagation merupakan data hasil panen petani kakao pada tahun 2019-2023 dengan total sebanyak 2.980 data. Setelah dilakukan preprocessing total data berkurang menjadi 2910 data. Tahapan preprocessing data dilakukan untuk dapat menghasilkan data yang berkualitas baik dan siap digunakan dalam proses analisis lebih lanjut atau proses prediksi. Tahapan ini dilakukan dengan beberapa langkah, dimulai dengan melakukan proses *Exploratory Data Analysis* untuk menemukan dan menangani data yang hilang atau tidak lengkap, pembersihan data yang tidak dibutuhkan, transformasi data yang terdiri dari mengonversi angka persentase ke desimal, label encoding dengan tujuan data dapat diproses oleh model machine learning, dan normalisasi. Data yang telah dikumpulkan kemudian dibagi menjadi data training dan data testing menggunakan konsep rasio yaitu 70:30, 80:20, 90:10. Adapun sample data yang digunakan dalam penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Sample Data

No	Luas Lahan (Ha)	Jumlah Pohon	Jenis Bibit	Jenis Pupuk	Hama & Penyakit (%)	Penanggulangan Hama & Penyakit	Tingkat Curah Hujan	Hasil (Kg)
1	0.69	750	Forastero Dan Trinatrio	Npk Dan Sampurna B	15.6%	Pestisida Dan Pemangkasan	Tinggi	526
2	0.2	332	Forastero	Green Tama Dan Sampurna B	33.1%	Pestisida	Tinggi	148
3	1.3	1335	Forastero Dan Trinatrio	Green Tama Dan Sampurna B	16.5%	Pestisida Dan Pemangkasan	Tinggi	1003
4	0.69	750	Forastero Dan Trinatrio	Npk Dan Sampurna B	11.1%	Pestisida Dan Pemangkasan	Rendah	543
5	0.2	332	Forastero	Npk Dan Sampurna B	22.3%	Pestisida	Rendah	158
6	1.3	1335	Forastero Dan Trinatrio	Npk Dan Sampurna B	13.6%	Pestisida Dan Pemangkasan	Rendah	1021

Tabel 1 merupakan sample data yang digunakan dalam penelitian ini. Data tersebut diperoleh dari data hasil panen petani kakao Desa Minanga, Kecamatan Bambang, Kabupaten Mamasa dengan terlebih dahulu menghapus nama petani. Variabel input yang digunakan dalam penelitian ini yaitu luas lahan, jumlah tanaman kakao, jenis bibit, jenis pupuk, hama dan penyakit, penanggulangan hama dan penyakit, tingkat curah hujan, hasil. Total data yang digunakan dalam penelitian ini untuk diolah sebanyak 2.980, dengan menggunakan 8 kriteria dimana kriteria hasil sebagai variabel dependen yang akan di prediksi nilai nya berdasarkan pengaruh dari 7 kriteria lain (luas lahan, jumlah tanaman kakao, jenis bibit, jenis pupuk, hama & penyakit, penanggulangan hama & penyakit, tingkat curah hujan).

a. Luas lahan

Luas lahan mempengaruhi produksi tanaman karena semakin besar luas lahan, semakin banyak tanaman yang dapat ditanam sehingga jumlah hasil panen yang dihasilkan tinggi. Luas lahan yang besar tentu saja akan menghasilkan hasil panen yang banyak jika tidak ada penyebab faktor berkurangnya panen seperti hama, curah hujan dan lain -lain [15].

b. Jumlah tanaman kakao

Semakin banyak jumlah pohon tanaman kakao dalam sebuah lahan akan semakin meningkat hasil panen. Banyaknya jumlah pohon kakao yang aktif dalam berproduksi memiliki dampak signifikan terhadap hasil produksi [16].

c. Jenis bibit

Jenis bibit sangat berpengaruh terhadap produktivitas dan kualitas biji kakao yang dihasilkan. Selain itu, bibit membawa gen dari tanaman induk yang akan menentukan karakteristik tanaman setelah berbuah. Oleh karena itu variabel jenis bibit berpengaruh terhadap hasil panen. [16].

d. Jenis pupuk

Pupuk adalah kebutuhan utama pada setiap tanaman yang bermanfaat untuk meningkatkan pertumbuhan dan produktivitas tanaman. Pupuk yang umumnya biasa digunakan oleh petani yaitu pupuk anorganik karena mudah terurai dan langsung digunakan oleh tanaman. Pupuk ini dapat mensuplai ketiga unsur hara seperti nitrogen, fosfor, dan kalium [17].

e. Persentase Hama dan penyakit

Serangan hama dan penyakit adalah salah satu faktor utama yang menjadi penghambat peningkatan produksi dalam usaha tani kakao. Hama adalah organisme yang merusak atau mengganggu pertumbuhan dan kesehatan tanaman, seperti tikus, penggeret buah (kumbang). Begitupun dengan penyakit yang disebabkan oleh mikroorganisme seperti penyakit busuk buah, penyakit kanker batang, penyakit daun kering, dan parasit [18].

f. Penanggulangan hama dan penyakit

Menurut [19], salah satu faktor menurunnya jumlah produksi dalam setiap tanaman adalah tanpa adanya pengendalian hama dan penyakit. Sehingga penanggulangan hama dan penyakit adalah suatu pekerjaan yang harus dilakukan bagi petani dan sangat penting oleh tanaman.

g. Tingkat curah hujan

Curah hujan di setiap daerah di Indonesia memiliki tingkat keberagaman. Curah hujan merupakan jumlah air hujan yang turun di setiap daerah tertentu, yang diukur dalam bentuk harian, bulanan dan tahunan dalam skala milimeter [20]. Beberapa pengaruh curah hujan terhadap tanaman kakao seperti busuk buah akibat dari biji kakao yang terlalu banyak air.

h. Hasil

Tanaman kakao merupakan tanaman dengan komoditi yang berjangka panjang [4]. Untuk memprediksi hasil panen kakao, informasi tentang hasil panen sebelumnya harus diketahui terlebih dahulu. Hasil panen petani kakao di Desa Minanga memperoleh hasil yang bervariasi setiap musimnya. Biasanya hasil panen petani bisa mencapai 200 hingga 1000 kg dalam satu kali musim.

3.2 Training

Pelatihan pada Jaringan Saraf Tiruan dengan Backpropagation bertujuan untuk mengidentifikasi kerangka data dengan berdasarkan inputan parameter yang terdapat pada JST. Proses pelatihan data dimulai saat input layer menerima data training kemudian diteruskan ke hidden layer untuk diproses. Selanjutnya, data diteruskan ke output layer untuk menghasilkan keluaran. Proses pelatihan ini berhenti jika target error atau jumlah iterasi yang ditentukan telah tercapai. Tabel 2 menunjukkan beberapa parameter yang digunakan dalam pelatihan diantaranya arsitektur, learning rate, target error, serta fungsi aktivasi.

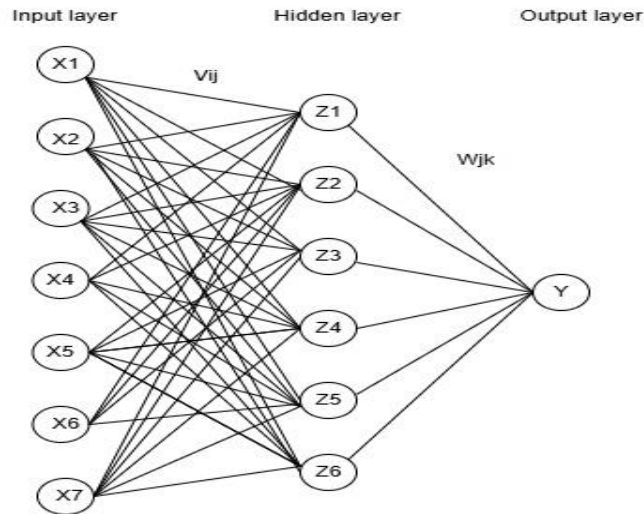
Tabel 2. Parameter Pelatihan

Parameter	Nilai
Arsitektur	7-4-1, 7-5-1, 7-6-1
Learning Rate	0.01, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9
Target Error	0.001, 0.0001
Fungsi Aktivasi	Sigmoid biner

Penelitian ini menggunakan arsitektur Jaringan Syaraf Tiruan (JST) dengan konfigurasi *multilayer perceptron*. Berdasarkan Tabel 2, terdapat empat komponen utama yang menjadi variabel dalam pengujian model, yaitu:

- Arsitektur Jaringan: Pengujian dilakukan pada tiga variasi struktur, yaitu 7-4-1, 7-5-1, dan 7-6-1. Angka tersebut merepresentasikan 7 neuron pada lapis masukan (*input layer*) dalam hal ini setiap neuron merepresentasikan variabel yang digunakan dalam melakukan prediksi, variasi 4 hingga 6 neuron pada lapis tersembunyi (*hidden layer*), dan 1 neuron pada lapis keluaran (*output layer*). Variasi ini bertujuan untuk menemukan jumlah neuron tersembunyi yang

paling optimal dalam menggeneralisasi pola data. Gambar 2 menunjukkan ilustrasi arsitektur jaringan dengan jumlah *hidden layer* sebanyak 6.



Gambar 2. Ilustrasi arsitektur jaringan 7-6-1

Gambar 2 merupakan ilustrasi arsitektur jaringan 7-6-1. Arsitektur tersebut menunjukkan jumlah neuron input sebanyak 7, diikuti oleh 6 hidden layer, dan 1 output. Neuron input merupakan titik awal di mana data mentah atau fitur-fitur dari dataset dimasukkan ke dalam jaringan, dimana setiap node mewakili satu variabel input. Struktur jaringan tersebut bersifat *fully connected*, artinya setiap neuron di satu lapisan terhubung ke setiap neuron di lapisan berikutnya. Koneksi ini memiliki bobot yang menentukan seberapa besar pengaruh sebuah input terhadap output.

- b. *Learning Rate*: Parameter ini ditentukan dalam rentang nilai 0,01 hingga 0,9. *Learning rate* berfungsi untuk mengontrol kecepatan penyesuaian bobot antar-neuron selama proses pelatihan. Nilai yang lebih kecil cenderung memberikan konvergensi yang lebih stabil namun lambat, sementara nilai yang lebih besar mempercepat durasi pelatihan dengan risiko terjadinya osilasi pada nilai error.
- c. Target Error: Kriteria penghentian pelatihan (*stopping condition*) ditetapkan pada nilai *Mean Squared Error* (MSE) sebesar 0,001 dan 0,0001. Penetapan target error yang rendah dimaksudkan agar model memiliki tingkat akurasi yang tinggi dan selisih antara nilai prediksi dengan nilai aktual sekecil mungkin.
- d. Fungsi Aktivasi: Seluruh neuron pada jaringan menggunakan fungsi aktivasi Sigmoid Biner (*Logistic Sigmoid*). Pemilihan fungsi ini didasarkan pada karakteristik data yang telah dinormalisasi ke dalam rentang [0, 1], serta sifat fungsi sigmoid yang dapat dideferensiasi, yang merupakan syarat utama dalam algoritma pembelajaran *backpropagation*.

3.3 Pengujian

Pengujian dilakukan pada 3 rasio data yaitu 70:30, 80:20, dan 90:10. Tahapan pengujian dilakukan hanya pada tahap proses perambatan maju dengan menggunakan model terbaik atau bobot terbaik yang diperoleh dari tahap pelatihan. Semakin mendekati antara hasil prediksi dan hasil aktual maka model tersebut masuk dalam prediksi yang baik. Hasil pengujian kemudian dilakukan proses denormalisasi untuk mengubah nilai dari rentang 0-1 menjadi bentuk awal untuk mempermudah proses evaluasi dengan data yang sebenarnya.

Tabel 3. Jumlah Data Training dan Testing

Rasio Data	Jumlah Data	
	Training	Testing
70 : 30	2.036	874
80 : 20	2.328	582
90 : 10	2.619	291

Tabel 3 menunjukkan pembagian dataset dalam penelitian ini dilakukan menggunakan tiga skenario rasio yang berbeda, yaitu 70:30, 80:20, dan 90:10. Rincian distribusi jumlah data untuk proses pelatihan (training) dan pengujian (testing). Variasi rasio ini digunakan untuk mengevaluasi stabilitas dan performa model dalam mengenali pola data.

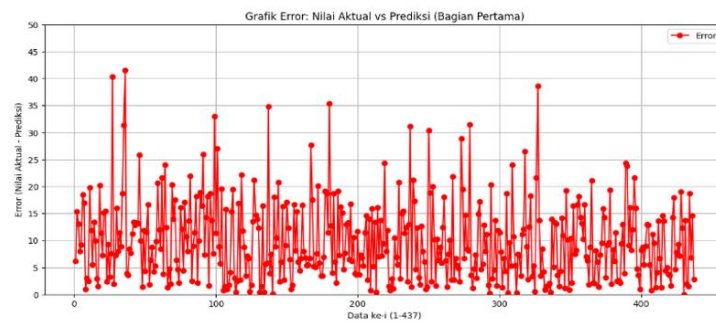
a. Rasio 70:30

Pengujian pertama menggunakan rasio data training dan testing sebesar 70:30 dengan total data testing sebanyak 874 data. Sample hasil perbandingan nilai aktual dan prediksi pada skenario ini ditunjukkan pada Tabel 4. Nilai aktual menunjukkan hasil panen sebenarnya sedangkan nilai prediksi adalah hasil panen yang diperoleh dari sistem.

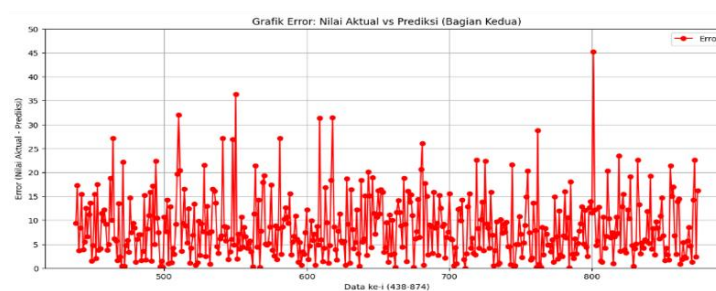
Tabel 4. Sample hasil perbandingan nilai aktual dan nilai prediksi

No	Nilai Aktual	Nilai Prediksi	Selisih
1	217	223.15	6.15
2	549	533.63	15.37
3	155	168.09	13.09
4	1015	1006.99	8.01
5	861	851.84	9.16
6	537	518.57	18.43
7	441	424.09	16.91
8	327	326.05	0.95
9	207	203.96	3.04
10	723	720.53	2.47
11	924	904.23	19.77
12	610	598.18	11.82
13	246	240.53	5.47
14	915	901.57	13.43
15	264	254.09	9.91

Tabel 4 menunjukkan sample hasil perbandingan nilai aktual dan nilai prediksi menunjukkan bahwa selisih antara nilai aktual dan nilai prediksi relatif kecil. Sebagai contoh, pada data ke-8, nilai aktual sebesar 327 berhasil diprediksi dengan sangat mendekati yaitu 326,05 dengan selisih 0,95. Secara keseluruhan, fluktuasi selisih yang rendah ini mengindikasikan bahwa bobot yang terbentuk selama proses pelatihan telah mampu mengenali pola data panen di Desa Minanga dengan baik. Untuk keseluruhan perbandingan hasil pengujian, ditunjukkan pada grafik nilai error pada Gambar 3.



(a) Grafik error antara hasil prediksi dan hasil aktual data ke 1-437



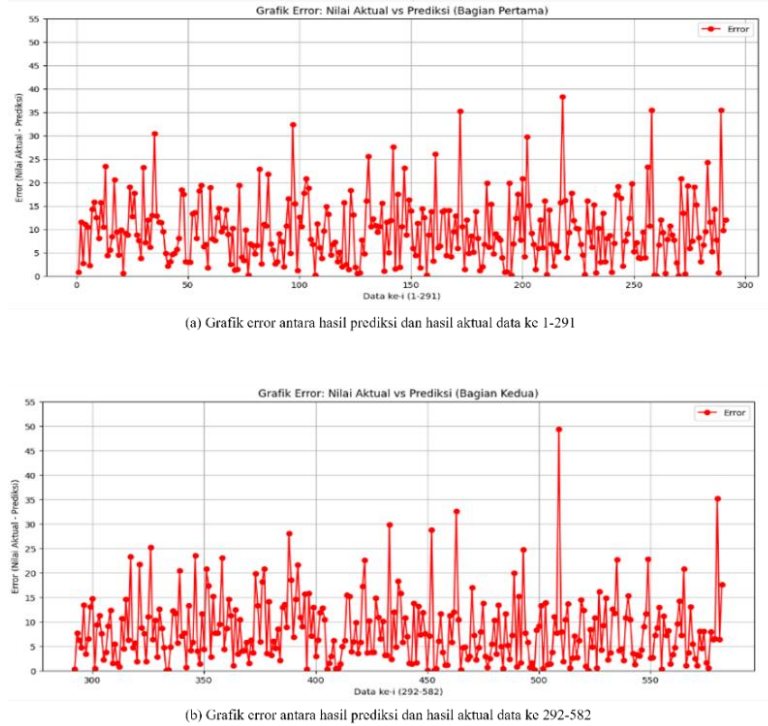
(b) Grafik error antara hasil prediksi dan hasil aktual data ke 438-874

Gambar 3. Grafik error pengujian pada rasio data 70:30

Gambar 3 menunjukkan grafik perbandingan nilai aktual dan prediksi pada rasio data 70:30 dimana grafik tersebut dibagi menjadi dua bagian. Gambar 1 bagian a menunjukkan selisih pada data pertama sampai 437, sedangkan bagian b untuk data 438 sampai 874. Nilai error berkisar dari 0 hingga 45 yang menunjukkan semakin mendekati nol maka prediksi hampir mendekati dengan nilai aktual dan semakin naik atau tinggi grafiknya menunjukkan bahwa prediksi memiliki error yang besar. Hasil pengujian tersebut model cenderung menghasilkan prediksi yang cukup akurat untuk sebagian besar data uji, tetapi masih ada beberapa model yang menghasilkan error yang signifikan seperti yang terlihat di grafik pada data ke- 28, ke- 37 dan ke -802 memiliki selisih yang cukup tinggi yaitu mencapai lebih dari 40.

b. Rasio 80:20

Pengujian kedua menggunakan rasio perbandingan data 80:20, dimana jumlah data training yang digunakan sebanyak 2.328 dan data testing sebanyak 582. Hasil Pengujian pada skenario ini ditunjukkan pada Gambar 4.




Gambar 4. Grafik error pengujian pada rasio data 80:20

Hasil pengujian ditunjukkan oleh grafik pada gambar 4 yang menunjukkan selisih antara nilai aktual dan nilai prediksi untuk setiap data uji. Nilai error berkisar dari 0 hingga 50 yang menunjukkan semakin mendekati nol maka prediksi hampir mendekati dengan nilai aktual dan semakin naik atau tinggi grafiknya menunjukkan bahwa prediksi memiliki error yang besar. Hasil pengujian tersebut model cenderung menghasilkan prediksi yang cukup akurat untuk sebagian besar data uji, tetapi masih ada beberapa model yang menghasilkan error yang signifikan seperti yang terlihat di grafik pada data ke-510 memiliki selisih yang cukup tinggi yaitu hampir mendekati 50.

c. Rasio 90:10

Skenario pengujian ketiga dilakukan dengan menggunakan rasio data 90:10. Pengujian ini melibatkan data pelatihan sebanyak 2.619 dan pada tahap pengujian menggunakan 291 data. Hasil pengujian antara nilai aktual dan nilai prediksi dapat ditunjukkan melalui grafik error pada Gambar 5.



Gambar 5. Grafik error pengujian pada rasio data 90:10

Gambar 5 menunjukkan selisih antara nilai aktual dan nilai prediksi untuk setiap data uji. Nilai error berkisar dari 0 hingga lebih dari 40, yang menunjukkan semakin mendekati nol maka prediksi hampir mendekati dengan nilai aktual dan semakin naik atau tinggi grafiknya menunjukkan bahwa prediksi memiliki error yang besar. Hasil pengujian tersebut model cenderung menghasilkan prediksi yang cukup akurat untuk sebagian besar data uji, tetapi masih ada beberapa model yang menghasilkan error yang signifikan seperti yang terlihat di grafik pada data ke- 219 memiliki selisih yang cukup tinggi yaitu mencapai lebih dari 40.

d. Perbandingan akurasi

Tahap evaluasi dilakukan untuk mengukur sejauh mana keakuratan model Jaringan Saraf Tiruan yang telah dibangun dalam memprediksi hasil panen. Evaluasi ini menggunakan parameter Mean Absolute Percentage Error (MAPE) dan persentase Akurasi. Pengujian dilakukan dengan membandingkan performa model pada tiga skenario pembagian data yang berbeda. Hasil perbandingan nilai MAPE dan akurasi untuk masing-masing rasio data tersebut dirangkum dalam Tabel 5 berikut.

Tabel 5. Perbandingan nilai MAPE dan Akurasi

Rasio Data	MAPE (%)	Akurasi (%)
70 : 30	2.05	97.95
80 : 20	2.11	97.89
90 : 10	1.91	98.09

Hasil pengujian performa model Jaringan Saraf Tiruan berdasarkan variasi rasio data disajikan pada Tabel 5. Berdasarkan hasil tersebut, seluruh skenario rasio menunjukkan tingkat akurasi yang sangat tinggi, yakni di atas 97%. Performa terbaik dicapai pada skema rasio data 90:10 dengan nilai MAPE terendah sebesar 1,91% dan tingkat akurasi mencapai 98,09%. Sementara itu, rasio 70:30 dan 80:20 masing-masing menghasilkan nilai MAPE sebesar 2,05% dan 2,11%.

3.4 Pembahasan

Berdasarkan hasil pengujian dengan menggunakan 3 rasio data, perbandingan 90:10 menghasilkan nilai MAPE lebih kecil serta akurasi paling tinggi dengan nilai 98.09%. Nilai akurasi tersebut diperoleh dengan arsitektur 7-6-1, learning rate 0.4, dan target error 0.0001 yang menunjukkan hasil prediksi tidak jauh berbeda dengan data sebenarnya. Berdasarkan hasil pengujian dari masing masing rasio dan parameter, nilai yang memiliki akurasi rendah yaitu target error 0.001. Hal ini dapat disimpulkan bahwa hasil akurasi yang dihasilkan dari setiap rasio dan parameter bergantung pada target error yang digunakan, semakin kecil target error maka akurasi yang dihasilkan semakin tinggi karena semakin banyak iterasi dilakukan, sehingga nilai error yang dihasilkan semakin kecil. Rendahnya nilai MAPE pada seluruh pengujian yang berada di bawah 10% mengindikasikan bahwa model *Backpropagation* yang dikembangkan memiliki kemampuan peramalan yang akurat dalam memprediksi hasil panen kakao. Hasil prediksi tersebut dapat membantu mengatasi masalah ketidakpastian pendapatan serta para petani dapat lebih mudah merencanakan anggaran, menentukan biaya perawatan, dan menyesuaikan strategi keuangan.

4. KESIMPULAN

Berdasarkan rangkaian tahapan penelitian yang telah dilaksanakan, dapat disimpulkan bahwa implementasi algoritma Jaringan Saraf Tiruan (JST) dengan metode *Backpropagation* terbukti sangat efektif dan reliabel sebagai instrumen prediksi hasil panen kakao di Desa Minanga, Kecamatan Bambang. Hasil pengujian melalui analisis grafik error pada seluruh rasio, baik 70:30, 80:20, dan 90:10 menunjukkan tren yang stabil di mana mayoritas selisih data berada pada rentang yang rendah. Meskipun terjadi fluktuasi pada beberapa titik data, mayoritas selisih antara nilai aktual dan nilai prediksi berada pada rentang yang cukup rendah. Pencapaian performa paling unggul diperoleh pada skenario rasio data 90:10 dengan konfigurasi arsitektur jaringan 7-6-1, learning rate 0,4, dan target error 0,0001. Kombinasi parameter ini menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 1,91% dan tingkat akurasi mencapai 98,09%. Nilai MAPE yang berada di bawah 10% mengukuhkan bahwa model ini masuk dalam kategori peramalan dengan tingkat presisi yang tinggi. Algoritma JST *Backpropagation* terbukti efektif dalam memprediksi hasil panen kakao dengan mempertimbangkan delapan kriteria input yang kompleks. Model ini mampu mengenali pola data historis dari tahun 2019-2023 secara presisi, terbukti dari kecilnya selisih antara nilai aktual dan nilai prediksi pada data uji. Berdasarkan dari hasil pengujian, algoritma Jaringan Saraf Tiruan metode *Backpropagation* dapat digunakan sebagai alternatif untuk memprediksi hasil panen kakao di Desa Minanga, Kecamatan Bambang, Kabupaten Mamasa.

UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih kepada Pemerintah Desa Minanga beserta jajarannya yang telah memfasilitasi akses data penelitian. Bantuan ini merupakan kontribusi penting dalam keberhasilan pengembangan model prediksi pada penelitian ini.

REFERENCES

- [1] F. Santika and D. Novirani, "Peramalan Metode Time Series Terhadap Produksi Kakao di Kabupaten Batang," *e-Proceeding FTI*, vol. 1, no. 1, Jul. 2022, [Online]. Available: <https://eproceeding.itenas.ac.id/index.php/fti/article/view/1029>
- [2] L. Syafira and Helma, "Penerapan Metode Autoregressive Distributed Lag pada Prediksi Produksi Kakao Indonesia," *J. Math. UNP*, vol. 7, no. 3, pp. 74–82, 2022.
- [3] Samsari, I. A.P, and N. Zulkarnaim, "Prediksi Produktivitas Kakao Kabupaten Mamuju dengan Algoritma K-Nearest Neighbor," *In Search*, vol. 17, no. 02, pp. 35–39, 2018, [Online]. Available: https://repository.unibi.ac.id/298/1/MENGGALI_INFORMASI_EDUKATIF_DI_MEDIA_SOSIAL.pdf
- [4] B. Basri, N. Umar, and Z. Sitti, "Sistem Pendukung Keputusan Prediksi Hasil Panen Tanaman Kakao dengan Metode Naive Bayes Berbasis Android," *Proceeding Konik (Konferensi Nas. Ilmu Komputer)*, pp. 290–294, 2020.
- [5] H. W. Herwanto, T. Widiyaningtyas, and P. Indriana, "Penerapan Algoritme Linear Regression untuk Prediksi Hasil Panen Tanaman Padi," *Natl. J. Electr. Eng. Inf. Technol.*, vol. 8, no. 4, p. 364, 2019.
- [6] R. Maiyuriska, "Penerapan Jaringan Syaraf Tiruan dengan Algoritma Backpropagation dalam Memprediksi Hasil Panen Gabah Padi," *J. Inform. Ekon. Bisnis*, vol. 4, pp. 28–33, 2022, doi: 10.37034/infob.v4i1.115.
- [7] A. F. Suahati, A. A. Nurrahman, and O. Rukmana, "Penggunaan Jaringan Syaraf Tiruan – Backpropagation dalam Memprediksi Jumlah Mahasiswa Baru," *J. Media Tek. dan Sist. Ind.*, vol. 6, no. 1, p. 21, 2022, doi: 10.35194/jmtsi.v6i1.1589.
- [8] R. R. Putra, "Implementasi Metode Backpropagation Jaringan Saraf Tiruan Dalam Memprediksi Pola Pengunjung Terhadap Transaksi," *J. Teknol. Inf.*, vol. 3, no. 1, pp. 16–20, 2019, [Online]. Available: <file:///C:/Users/User/Downloads/fvm939e.pdf>
- [9] H. Putra and N. U. Walmi, "Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation," *J. Nas. Teknol. dan Sist. Inf.*, vol. 06, no. 02, pp. 100–107, 2020.
- [10] T. B. Harahap, L. S. Harahap, and N. N. Hasibuan, "Penerapan Jaringan Saraf Tiruan dengan Metode Backpropagation untuk Memprediksi Curah Hujan di Kota Medan," *Polyg. J. Ilmu Komput. dan Ilmu Pengetah. Alam*, vol. 4, no. 1, 2026.
- [11] F. Khairati and H. Putra, "Prediksi Kuantitas Penggunaan Obat pada Layanan Kesehatan Menggunakan Algoritma Backpropagation Neural Network," *J. Sistim Inf. dan Teknol.*, vol. 4, pp. 128–135, 2022, doi: 10.37034/jsisfotek.v4i3.158.
- [12] R. Hartono and A. Zein, "Penerapan Algoritma Genetika dan Jaringan Syaraf Tiruan Dalam Penjadwalan Mata Kuliah Studi Kasus: Prodi Sistem Informasi Universitas Pamulang," *J. Ilmu Komput.*, vol. 6, no. 3, pp. 7–10, 2023.
- [13] F. Sinuhaji, D. E. Tarigan, and J. A. Humendru, "Prediksi Total Warga Kabupaten Karo Pada Tahun 2040 Menggunakan Jaringan Saraf Tiruan Metode Bacpropagation," *J. Curere (Jurnal Ilm. Fak. Kegur. dan Ilmu Pendidikan)*, vol. 7, no. 2, pp. 119–128, 2023.
- [14] I. Nabillah and I. Ranggadara, "Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut," *JOINS (Journal Inf. Syst.*, vol. 5, no. 2, pp. 250–255, 2020, doi: 10.33633/joins.v5i2.3900.
- [15] A. D. L. Ervan Triyanto, Heri Sismoro, "Implementasi Algoritma Regresi Linear Berganda Untuk Memprediksi Produksi Padi Di Kabupaten Bantul," vol. 4, no. 2, pp. 73–86, 2019.
- [16] M. R. Panna, Marhawati, Nurdiana, Mustari, and T. Supatminingsih, "Analisis Faktor-Faktor yang Memengaruhi Produksi Kakao di Kecamatan Tapango Kabupaten Polewali Mandar," *Soc. J. Soc. Sci. Humanit.*, vol. 1, no. 2, pp. 1–11, 2021, [Online]. Available: <https://ojs.unm.ac.id/societies/index>
- [17] Y. H. Bertham, B. G. M, and K. Utami, "Peningkatan Pengetahuan Masyarakat Dalam Pemberian Pupuk Organik Dan Anorganik Untuk Produktivitas Tanaman," *JMM (Jurnal Masy. Mandiri)*, vol. 6, no. 4, pp. 2961–2972, 2022.
- [18] U. Khairul, T. Trizelia, and R. Reflin, "Pemberdayaan Kelompok Tani Melalui Pelatihan Pengendalian Hama Dan Penyakit Tanaman Kakao Di Kanagarian Campago Kabupaten Padang Pariaman," *Bul. Ilm. Nagari Membangun*, vol. 1, no. 4, pp. 88–95, 2018, doi: 10.25077/bnm.1.4.88-95.0.
- [19] Yuspan, F. Pasaru, and M. Yunuus, "Kepadatan Populasi dan Intensitas Serangan Hama Kepik Penghisap Buah Kakao (*Helopeltis spp.*) pada Tanaman Kakao (*Theobroma Cacao l.*) di Desa Lonu, Kecamatan Bunobogi, Kabupaten Buol," *e-J. Agrotekbis*, vol. 10, no. 3, pp. 183–191, 2022.
- [20] R. Ruqoyah, Y. Ruhiat, and A. Saefullah, "Analisis Klasifikasi Tipe Iklim Dari Data Curah Hujan Menggunakan Metode Schmidt-Ferguson (Studi Kasus : Kabupaten Tangerang)," *J. Teor. dan Apl. Fis.*, vol. 11, no. 01, pp. 29–38, 2023.