

**ARTIFICIAL NEURAL NETWORK UNTUK MEMPREDIKSI PRODUKSI TANAMAN MENGGUNAKAN METODE BACKPROPAGATION DI DINAS PERTANIAN DAN PANGAN KABUPATEN MAGELANG PROVINSI JAWA TENGAH (STUDI PADA PRODUKSI TAMANAN CABAI)**

Sakti Wira Adi Utomo

NPP. 32.0470

Asdaf Kabupaten Magelang, Provinsi Jawa Tengah

Program Studi Teknologi Rekayasa Informasi Pemerintahan

Email: [saktiwira@gmail.com](mailto:saktiwira@gmail.com)

Pembimbing Skripsi: Rina Wahyuni, S.Kom., M.T.I.

**ABSTRACT**

**Problem Statement/Background (GAP):** The Department of Agriculture and Food of Magelang Regency faces challenges in providing accurate and detailed data on chili production. This issue is critical as Magelang is one of the largest chili-producing centers in Central Java, with a total production reaching 880,983.19 quintals in 2024. Resource limitations, especially in field data collection, pose a major obstacle to regularly estimating production across the entire region. Yet, chili production data is essential for policy-making in market regulation and food price stabilization. **Purpose:** To address this problem, this study aims to develop a chili production prediction model using the Artificial Neural Network (ANN) method with the Backpropagation algorithm, to support more efficient and accurate production estimation. **Method:** A qualitative research method was employed, with data collected from documentation provided by the Department of Agriculture and Food of Magelang, the SIPEDAS website, and interviews(12 Informants). **Result:** The research findings indicate that the ANN model built using Altair AI Studio successfully produced accurate predictions. The best-performing architectures identified were 12-25-1 for large chili and 12-15-1 for bird's eye chili. **Conclusion:** This model has proven useful in supporting strategic planning for supply and price stabilization by relevant agencies. The study also recommends further model improvements, including exploring more diverse architectures, incorporating additional variables such as land area and rainfall, and comparing ANN performance with other predictive algorithms.

**Keywords:** Artificial Neural Network, Production Prediction, Backpropagation

**ABSTRAK**

**Permasalahan/Latar Belakang (GAP):** Dinas Pertanian dan Pangan Kabupaten Magelang menghadapi tantangan dalam menyediakan data produksi cabai yang akurat dan mendetail. Hal ini menjadi persoalan penting mengingat Kabupaten Magelang merupakan salah satu sentra penghasil cabai terbesar di Jawa Tengah, dengan total produksi mencapai 880.983,19 kuintal pada tahun 2024. Keterbatasan sumber daya, khususnya dalam hal perhitungan produksi di lapangan, menjadi hambatan utama dalam menghitung besaran

produksi secara rutin di seluruh wilayah kabupaten. Padahal, data produksi cabai sangat krusial sebagai dasar pengambilan kebijakan dalam pengendalian pasar dan stabilisasi harga pangan. **Tujuan:** Untuk menjawab permasalahan tersebut, penelitian ini bertujuan membangun model prediksi produksi cabai menggunakan metode Artificial Neural Network (ANN) dengan algoritma Backpropagation, guna membantu estimasi produksi secara lebih efisien dan akurat. **Metode:** Metode yang digunakan dalam penelitian ini adalah metode kualitatif, dengan pengumpulan data melalui dokumentasi dari Dinas Pertanian dan Pangan Kabupaten Magelang, situs web SIPEDAS, serta wawancara (12 Informan). **Hasil/Temuan:** Hasil penelitian menunjukkan bahwa model ANN yang dibangun menggunakan Altair AI Studio berhasil menghasilkan prediksi yang baik. Arsitektur terbaik yang diperoleh adalah 12-25-1 untuk produksi cabai besar, dan 12-15-1 untuk cabai rawit. **Kesimpulan:** Model ini terbukti mampu membantu perencanaan langkah strategis stabilisasi pasokan dan harga pangan oleh instansi terkait. Penelitian ini juga merekomendasikan beberapa pengembangan lanjutan untuk meningkatkan kualitas model, antara lain dengan mengeksplorasi arsitektur model yang lebih variatif, menambahkan atribut pendukung seperti luas lahan dan curah hujan, serta membandingkan performa ANN dengan algoritma prediksi lainnya. **Kata Kunci:** *Artificial Neural Network, Prediksi Produksi, Backpropagation*

## I. PENDAHULUAN

### 1.1. Latar Belakang

Pertanian merupakan salah satu sektor yang memiliki peran sangat penting dalam pembangunan perekonomian bangsa. Pemerintah telah berkomitmen untuk melaksanakan program revolusi hijau melalui peningkatan produksi di sektor pertanian sebagai tumpuan utama dalam memenuhi kebutuhan pangan nasional. Letak geografis Indonesia yang berada di garis khatulistiwa dengan iklim tropis memberikan keuntungan tersendiri dalam pengembangan sektor pertanian (Idris et al., 2022). Salah satu wilayah strategis dalam sektor pertanian adalah Kabupaten Magelang yang merupakan salah satu sentra penghasil cabai merah di Provinsi Jawa Tengah. Menurut data yang diambil dari Badan Pusat Statistik Kabupaten Magelang (2025) Kabupaten Magelang merupakan penghasil cabai tertinggi di Jawa Tengah dengan total produksi untuk ketiga jenis cabai baik cabai merah, cabai rawit, dan cabai keriting pada tahun 2024 sebanyak 880.983,19 kuintal dan menyumbangkan 19,6% total pasokan cabai yang diproduksi di seluruh wilayah Jawa Tengah. Kabupaten Magelang sebagai salah satu produsen cabai tertinggi di Jawa Tengah mengakibatkan persediaan cabai di Kabupaten Magelang selalu surplus tiap waktunya sehingga harga dari cabai yang tersedia di kabupaten Magelang selalu berada di bawah harga pasar dibanding di daerah lain di Jawa Tengah. Kondisi ini menjadi tantangan sekaligus peluang bagi pemerintah daerah untuk mengambil peran strategis dalam menjaga kestabilan harga dan distribusi cabai. Sebagaimana dijelaskan oleh Dede Maryani dan Ruth Roselin E. Nainggolan dalam buku Pemberdayaan Masyarakat, kehadiran dan keberadaan pemerintah dimaksudkan untuk melayani Masyarakat. Pemerintah memiliki kewajiban untuk melayani Masyarakat dalam meningkatkan taraf kehidupannya. (Maryani & Nainggolan, 2019)

Pemerintah dapat memberdayakan petani melalui berbagai langkah pembinaan, sebagaimana dijelaskan dalam penelitian oleh Halim (2020) Pembinaan dapat dilakukan dengan bina manusia, yang dilakukan melalui pendidikan, pelatihan, penyuluhan, dan pendampingan; bina lingkungan, yang diwujudkan melalui pembinaan dan pendampingan dalam pengendalian Organisme Pengganggu Tanaman (OPT) secara ramah lingkungan, bina usaha, melalui pembinaan dan pendampingan dalam penerapan teknologi produksi, bina usaha dalam aspek pengolahan dan pemasaran hasil, serta bina kelembagaan melalui penguatan kelompok tani. Dalam hal ini, Pemerintah Kabupaten Magelang melalui Dinas Pertanian dan Pangan memiliki

peran penting dalam pengendalian pasar. Untuk itu, besar peran Kabupaten Magelang melalui Dinas Pertanian dan Pangan Kabupaten Magelang selama ini khususnya dalam mengendalikan pasar cabai di Jawa Tengah. Pengendalian harga pasar cabai dilakukan melalui pengendalian harga cabai yang selalu di bawah harga pasar juga distribusi persediaan tanaman cabai ke daerah lain di Jawa Tengah yang mengalami kenaikan harga cabai akibat kurangnya persediaan dibandingkan permintaan yang ada.

## 1.2. Kesenjangan Masalah yang Diambil (GAP Penelitian)

Persediaan cabai di Kabupaten Magelang perlu diperhatikan karena Kabupaten Magelang memegang peran penting dalam pengendalian harga cabai di Jawa Tengah. Namun, ditemukan bahwa Dinas Pertanian Kabupaten Magelang mengalami kesulitan dalam menyediakan besaran produksi pasokan cabai yang akurat dan mendetail. Hal tersebut disebabkan oleh kurangnya kemampuan penyuluh untuk turun ke lapangan setiap hari melakukan perhitungan besaran produksi cabai di seluruh daerah di Kabupaten Magelang. Padahal perhitungan besaran produksi cabai merupakan hal penting untuk dijadikan dasar pengambilan keputusan pengendalian terhadap pasar cabai di Jawa Tengah.

Seperti yang disimpulkan oleh Ma'ruf et al. (2021), Penerapan Sistem Informasi Manajemen (SIM) merupakan sistem yang mengolah serta mengorganisasikan data dan informasi yang berguna untuk mendukung pelaksanaan tugas dalam suatu organisasi yang sering terlupakan. Dalam rangka mengatasi permasalahan tersebut, diperlukan inovasi berbasis teknologi yang mampu memberikan solusi atas keterbatasan sumber daya dan kemampuan penyuluh di lapangan. Salah satu pendekatan yang dapat digunakan adalah penerapan teknologi *Machine Learning* untuk melakukan proyeksi dan prediksi produksi cabai. Melalui metode ini, diharapkan data yang lebih akurat dan mendetail dapat dihasilkan tanpa harus bergantung pada pengumpulan data manual yang memakan waktu dan tenaga. Fahle et al. (2020) menjelaskan bahwa *Machine Learning* merupakan suatu metode yang dapat membuat komputer melakukan pembelajaran berdasarkan pengalamannya tanpa perlu melakukan suatu pemrograman secara eksplisit. Berdasarkan beberapa artikel yang telah dikumpulkan dalam tinjauan literatur oleh Purmala (2021), Penerapan *Machine Learning* dengan algoritma *Neural Network* menjadi algoritma yang paling banyak digunakan untuk melakukan analisa dan prediksi sebab algoritma *Neural Network* memiliki beberapa kelebihan yang cocok diterapkan karena algoritma ini dapat belajar dari contoh dan menerapkannya ketika peristiwa serupa muncul, membuat mereka dapat bekerja melalui peristiwa yang saat itu terjadi dan Bahkan jika neuron tidak merespons atau ada informasi yang hilang, jaringan dapat mendeteksi kesalahan dan tetap menghasilkan suatu keluaran.

*Artificial Neural Network* (ANN) unggul dalam menangani data kompleks dengan ukuran besar dan pola non-linear. ANN, atau Jaringan Syaraf Tiruan, adalah sistem pemrosesan informasi yang menyerupai sistem saraf manusia. Algoritma ini dapat mempelajari hubungan kompleks antara masukan (*input*) dan keluaran (*output*) serta mengenali pola yang sulit diidentifikasi oleh metode lain. ANN juga memiliki kemampuan untuk memodelkan hubungan kompleks antara variabel masukan dan keluaran, menjadikannya pilihan yang ideal untuk prediksi data produksi cabai yang dipengaruhi oleh banyak faktor eksternal.

Adapun penelitian yang dilakukan oleh Mohamad et al. (2018) menyimpulkan bahwa model ANN PSO–BP (*Artificial Neural Network* dengan *Particle Swarm Optimization* dan *Backpropagation*) menunjukkan kinerja yang lebih unggul dibandingkan dengan model prediktif lainnya. Selain itu, penelitian yang dilakukan Kurani et al. (2023) menjelaskan bahwa *Artificial Neural Network* (ANN) menunjukkan hasil yang menjanjikan berdasarkan berbagai metode pengukuran, seperti MSE, RMSE, MAE, SSE, MARE, MSRE, RMSRE, MAPE, MSPE, dan RMSPE, serta rasio keberhasilan (*hit ratios*) dalam konteks LTM, FTM, dan GTM.

Lebih lanjut, kombinasi antara algoritma *Backpropagation* dan jaringan *Multilayer Feed-forward* dalam ANN terbukti mampu menghasilkan performa terbaik. Diperkuat oleh penelitian Asteris et al. (2016), yang menyatakan bahwa *Artificial Neural Network (ANN)* dapat diprediksi secara efektif menggunakan model jaringan saraf *multilayer feed-forward*, dengan tingkat kesalahan yang lebih rendah dan upaya komputasi yang lebih sedikit.

Berdasarkan uraian diatas, Pemecahan permasalahan terkait pemanfaatan proyeksi produksi cabai dengan menerapkan algoritma *Artificial Neural Network* perlu dilakukan oleh penulis agar kedepannya perkiraan jumlah produksi cabai di Kabupaten Magelang Provinsi Jawa Tengah dapat dilakukan dengan memanfaatkan hasil rekayasa teknologi informasi menggunakan metode *Machine Learning* yang menggunakan Sistem *Artificial Intelligence*.

### 1.3. Penelitian Terdahulu

Penelitian ini terinspirasi oleh beberapa penelitian terdahulu yang menerapkan metode *Artificial Neural Network (ANN)* dengan algoritma *Backpropagation* dalam berbagai bidang prediksi, baik pada sektor pendidikan, kesehatan, bisnis, maupun pertanian. Penelitian-penelitian tersebut menunjukkan bahwa ANN memiliki potensi yang tinggi dalam menghasilkan prediksi yang akurat terhadap data historis.

Penelitian oleh Salis et al. (2024) berjudul Implementasi Algoritma *Backpropagation* Untuk Prediksi Jumlah Siswa SMA menunjukkan bahwa algoritma *Backpropagation* cukup efektif dalam memprediksi jumlah siswa di Kota Pematangsiantar. Penelitian ini menghasilkan model arsitektur terbaik 4–25–1 dengan akurasi sebesar 87,5%, MSE pelatihan 0,000967055, dan MSE pengujian 0,001440343. Hasil tersebut memperkuat bahwa ANN dapat diandalkan dalam memodelkan pola data jumlah populasi berdasarkan tren historis.

Sementara itu, Putri et al. (2024) dalam penelitiannya yang berjudul Model Integrasi Algoritma *Spectral Clustering* dan *Backpropagation* Pada Prediksi Penjualan Barang, mencoba menggabungkan dua metode sekaligus. Hasilnya menunjukkan tingkat error MAPE sebesar 21,21%, menandakan bahwa integrasi metode ANN dan clustering dapat meningkatkan efisiensi prediksi dalam konteks data bisnis.

Penelitian oleh Sari et al. (2024) dengan judul Jaringan Syaraf Tiruan Prediksi Harga Pasar Teh Menggunakan Metode *Backpropagation* menemukan arsitektur jaringan terbaik 16–5–16, dengan akurasi mencapai 99% dan MSE training sebesar 1.1187. Penelitian ini menegaskan efektivitas *Backpropagation* dalam memprediksi fluktuasi harga pasar berdasarkan data historis.

Dalam ranah kesehatan, Marwati & Fauzi (2024) melakukan penelitian berjudul Prediksi Penyakit Diabetes Melitus Menggunakan Jaringan Syaraf Tiruan dengan Metode *Backpropagation*. Penelitian ini menghasilkan akurasi 80,75%, presisi 81,74%, dan nilai AUC sebesar 0,770. Meskipun objek kajiannya berbeda, temuan ini menunjukkan bahwa ANN juga mampu mengolah data klasifikasi dengan hasil yang cukup baik.

Penelitian oleh Sakina & Mirza (2024) dengan judul Prediksi Hasil Produksi Ikan Lele Menggunakan *Machine Learning* juga relevan dengan penelitian ini. Studi kasus pada Dinas Perikanan Kabupaten Muara Enim tersebut membandingkan metode ANN, *Random Forest*, dan *Decision Tree*, dan menyimpulkan bahwa ANN lebih unggul karena interpretabilitas dan kemampuannya dalam memprediksi hasil produksi perikanan.

Terakhir, Surya et al. (2021) dalam penelitiannya Komparasi Algoritma *Machine Learning* untuk Penentuan Performance Terbaik Pada Prediksi Produksi Tanaman Jahe di Indonesia menggunakan metode *Resilient Backpropagation* dan *Levenberg-Marquardt*. Penelitian ini menunjukkan bahwa arsitektur 4–15–1 memiliki performa terbaik dengan nilai

MSE sangat rendah, yaitu 0,0000000008. Temuan ini memperkuat pentingnya pemilihan arsitektur dan algoritma dalam pengembangan model prediksi produksi tanaman.

Keseluruhan penelitian terdahulu tersebut menjadi dasar penting bagi pengembangan model dalam penelitian ini, yang secara khusus mengadopsi metode *Backpropagation* untuk membangun model prediksi produksi cabai di Kabupaten Magelang sebagai bagian dari inovasi teknologi dalam mendukung pengambilan keputusan pemerintah daerah di sektor pangan

#### **1.4. Pernyataan Kebaruan Ilmiah**

Kebaruan ilmiah dari penelitian ini terletak pada penerapan metode *Artificial Neural Network (ANN)* dengan algoritma *Backpropagation* untuk membangun model prediksi produksi cabai yang secara khusus ditujukan sebagai alat bantu pengambilan keputusan oleh pemerintah daerah, dalam hal ini Dinas Pertanian dan Pangan Kabupaten Magelang. Berbeda dengan penelitian-penelitian sebelumnya yang umumnya berfokus pada sektor pendidikan, kesehatan, atau bisnis, penelitian ini diarahkan untuk mendukung fungsi pemerintahan dalam menjaga stabilitas pasokan dan harga komoditas pangan. Penelitian yang berorientasi pada inovasi institusi publik menjadikannya relevan secara praktis dan berbeda secara pendekatan, karena model prediksi yang dibangun tidak hanya mengejar akurasi, tetapi juga dirancang agar dapat diimplementasikan secara langsung dalam proses perencanaan program dan kebijakan pertanian daerah.

#### **1.5. Tujuan.**

Penelitian ini bertujuan untuk mengetahui bagaimana penerapan metode *Backpropagation* dalam memprediksi data produksi cabai di setiap kecamatan di Kabupaten Magelang Provinsi Jawa Tengah serta mengetahui bagaimana model prediksi data produksi cabai dapat digunakan dalam stabilisasi harga dan pasokan pangan di Kabupaten Magelang, Provinsi Jawa Tengah, dengan menggunakan *Backpropagation* terhadap pengambilan keputusan dalam pengelolaan produksi dan kestabilan harga cabai.

## **II. METODE**

Penelitian ini menggunakan metode deskriptif kualitatif. Adapun yang dimaksud dengan penelitian kualitatif yaitu penelitian yang bermaksud untuk memahami fenomena tentang apa yang dialami oleh subjek penelitian secara holistik, dan dengan cara deskripsi dalam bentuk kata-kata dan bahasa, pada suatu konteks khusus yang alamiah dan dengan memanfaatkan berbagai metode ilmiah (Moleong, 2007). Jenis penelitian deskriptif kualitatif yang digunakan pada penelitian ini dimaksudkan untuk mengetahui bagaimana metode *Backpropagation* dapat diterapkan dalam memprediksi data produksi cabai di setiap kecamatan di Kabupaten Magelang Provinsi Jawa Tengah secara mendalam dan komprehensif. Selain itu, dengan pendekatan kualitatif diharapkan dapat diungkapkan bagaimana kegiatan prediksi data produksi cabai dapat dimanfaatkan bagi pemerintah Kabupaten Magelang Provinsi Jawa Tengah.

Penulis mengumpulkan data primer melalui gabungan data yang didapat dari situs SIPEDAS Hortikultura dan data yang dikelola langsung oleh Dinas Pertanian dan Pangan Kabupaten Magelang, serta data sekunder melalui wawancara. Dalam melakukan pengumpulan data kualitatif, penulis melakukan wawancara terhadap 12 orang informan yang terdiri dari Petani Tanaman Cabai yang memberikan informasi mengenai kondisi lapangan, produksi, tantangan, dan pola penanaman. (3 orang), Penyuluh Pertanian memberikan gambaran teknis pengumpulan data lapangan dan pemahaman terhadap dinamika produksi (3 orang), Pegawai Pengelola Data yang bertanggungjawab atas sistem pengelolaan dan pencatatan data produksi di instansi. (4 orang), dan pejabat pengambil Keputusan yang memanfaatkan data prediksi dalam

pengambilan kebijakan (2 orang). Tahapan analisis data dalam pengembangan model prediksi produksi cabai menggunakan *Artificial Neural Network* (ANN) pada Altair AI Studio. Proses analisis mencakup pengumpulan data, *preprocessing*, pelatihan model arsitektur jaringan saraf, serta pengujian dan evaluasi model.

Penelitian ini dilaksanakan di Kabupaten Magelang, Jawa Tengah, selama kurun waktu 6 hingga 25 Januari 2025, sesuai dengan isi Surat Izin Penelitian Praja Utama Angkatan XXXII IPDN. Seluruh kegiatan dilakukan langsung di lingkungan Dinas Pertanian dan Pangan Kabupaten Magelang dan beberapa lokasi lapangan yang relevan seperti Balai Penyuluhan Pertanian dan Kehutanan Kecamatan dan petani penghasil cabai.

### III. HASIL DAN PEMBAHASAN

Penelitian ini membahas percobaan prediksi besaran produksi tanaman cabai di Kabupaten Magelang menggunakan Altair AI Studio dengan algoritma *Neural Network*. Uji coba dilakukan untuk memperoleh hasil prediksi jumlah produksi tanaman cabai per bulan di setiap kecamatan.

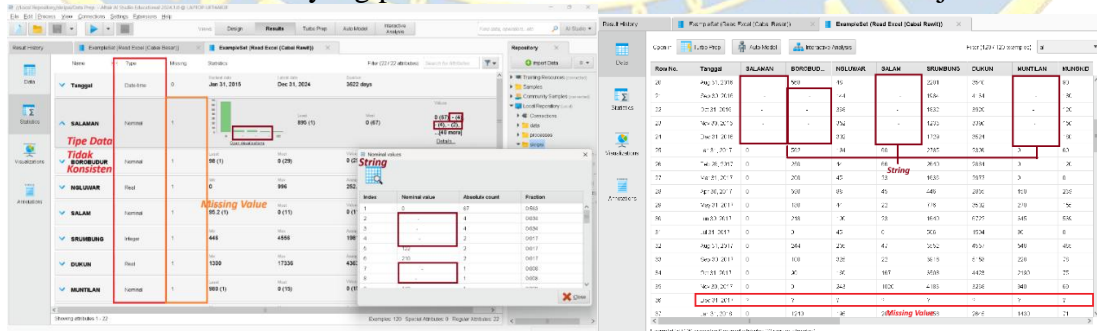
#### 3.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan gabungan dari data produksi tanaman cabai per bulan yang diperoleh dari Sistem Penyediaan Data Statistik Pertanian Hortikultura dan basis data produksi hortikultura Dinas Pertanian dan Pangan Kabupaten Magelang, dengan rentang waktu dari tahun 2015 hingga 2024. Sebelum diproses, data ini terlebih dahulu diolah, difilter untuk mengambil data khusus cabai, serta digabungkan dalam format *Excel* sebelum dimasukkan ke dalam sistem untuk analisis lebih lanjut.

Dataset dalam penelitian ini terbagi menjadi dua kategori, yaitu data produksi cabai besar dan cabai rawit, yang masing-masing dianalisis menggunakan algoritma *Neural Network* dalam Altair AI Studio. Setiap dataset terdiri dari 2.520 entri *time series* dengan 22 atribut, yang mencakup satu atribut tanggal per bulan dari 2015 hingga 2024, serta 21 atribut lainnya yang merepresentasikan jumlah produksi cabai di 21 kecamatan di Kabupaten Magelang. Dengan demikian, penelitian ini menghasilkan dua model prediksi yang masing-masing diterapkan pada dataset cabai besar dan cabai rawit.

#### 3.2. Preprocessing Data

Data yang telah dikumpulkan dan diolah sebelumnya kemudian dimasukkan ke dalam pemodelan menggunakan AI Studio. Dalam proses ini, berdasarkan analisis statistik data pada AI Studio seperti ditunjukkan pada kedua gambar dibawah, ditemukan beberapa ketidaksesuaian dalam data yang perlu disesuaikan sebelum analisis lebih lanjut.

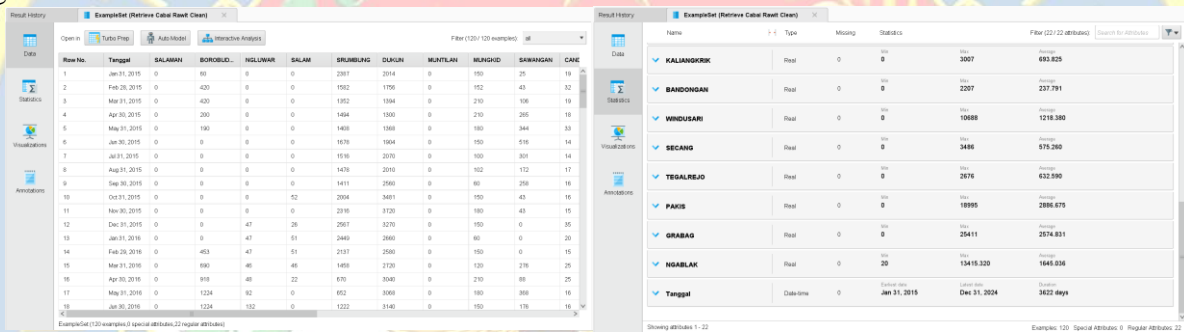


Gambar 1 Identifikasi Ketidaksesuaian pada Data Awal

Salah satu permasalahan yang ditemukan adalah adanya *missing value* dalam dataset, baik pada data cabai besar maupun cabai rawit. Setelah diteliti, *missing value* ini terdapat pada data produksi cabai bulan Desember tahun 2017. Karena data yang hilang hanya terjadi pada satu bulan, langkah yang diambil untuk mengisi *missing value* adalah dengan mencari selisih antara total produksi cabai tahunan yang tersedia di Badan Pusat Statistik Kabupaten Magelang (2017) dan jumlah produksi dari 11 bulan lainnya yang diperoleh dari dataset Dinas Pertanian dan Pangan.


Masalah lain yang ditemukan adalah keberadaan data string "-" yang sebenarnya menunjukkan bahwa pada bulan tersebut, kecamatan yang bersangkutan tidak menghasilkan produksi tanaman cabai. Untuk menangani hal ini, dilakukan beberapa langkah *preprocessing* tambahan. Pertama, digunakan operator *Trim* dalam AI Studio untuk menghapus spasi yang tidak konsisten (*leading and trailing spaces*) dari nilai atribut nominal yang dipilih. Setelah itu, dilakukan proses *replace* untuk mengganti semua string "-" dengan nilai 0 agar dapat diproses sebagai data numerik.

Melalui tahapan *preprocessing* ini, data menjadi lebih bersih dan siap digunakan dalam pemodelan prediksi produksi cabai di Kabupaten Magelang, sebagaimana ditampilkan pada gambar di bawah.




Gambar 2 Data Bersih dan Statistik Data Setelah Preprocessing

### 3.3. Pelatihan dan Permodelan Neural Network



Gambar 3 Alur Pemodelan Prediksi di Altair AI Studio

Gambar 3 menampilkan rangkaian permodelan model prediksi di Altair AI Studio. Pada proses ini, data yang telah melewati tahap pra-pemrosesan digunakan sebagai dataset utama dan dimasukkan ke dalam model melalui operator *Retrieve Data*. Dataset ini memiliki 21 atribut, yang masing-masing merepresentasikan jumlah produksi cabai di 21 kecamatan di Kabupaten Magelang. Karena model harus memprediksi produksi cabai untuk setiap kecamatan, diperlukan pelatihan model dengan 21 target berbeda. Untuk menangani hal ini, digunakan metode *multilabel modelling*, yang memungkinkan model belajar dan memprediksi banyak target dalam satu proses pelatihan yang memungkinkan model untuk mempelajari dan memprediksi lebih dari satu target sekaligus.



Gambar 4 Pelatihan Model Dalam Multi-Label Modelling

Pada gambar 4 ditunjukkan proses pelatihan model prediksi menggunakan fungsi *multi-label modelling* dalam Altair AI Studio. Dalam proses ini, metode *Neural Network* digunakan dengan berbagai konfigurasi parameter untuk menemukan model dengan performa terbaik dan akurasi prediksi yang optimal.

Pelatihan model diawali dengan operator *Select Attribute*, yang digunakan untuk memilih satu atribut produksi dalam dataset untuk diproses dalam satu waktu. Pemilihan satu atribut ini bertujuan untuk menghemat sumber daya komputasi serta mempercepat proses pelatihan. Setelah data dipilih, proses *windowing* diterapkan untuk membentuk dataset yang sesuai untuk prediksi *time series*. Hal ini dilakukan untuk menjaga konsistensi antara data pelatihan dan pengujian yang kemudian digunakan sebagai input ke dalam model prediksi.

Hasil prediksi kemudian dibandingkan dengan data aktual untuk menilai tingkat akurasi model. Operator *Apply Model* digunakan dalam tahap ini untuk menghasilkan dataset yang berisi hasil prediksi beserta data target aktualnya. Karena dataset hasil prediksi masih berbentuk kumpulan data *window*, proses pemilihan atribut dilakukan menggunakan operator *Select Attribute* untuk menyaring hanya atribut yang relevan, yaitu tanggal, data produksi aktual, dan hasil prediksi di setiap kecamatan. Operator *Rename* juga digunakan untuk mengganti nama atribut agar lebih mudah dipahami.

### 3.4. Pengujian dan Evaluasi Performa

Evaluasi performa dilakukan menggunakan fungsi *multi-label performance*, yang memungkinkan evaluasi dilakukan secara otomatis untuk setiap label yang ada karena model prediksi memiliki 21 label target. Operator *Performance Regression* digunakan untuk mengukur akurasi model prediksi dengan beberapa metrik utama, yaitu *Root Mean Squared Error* (RMSE) digunakan untuk mengukur rata-rata penyimpangan antara nilai prediksi dan nilai aktual, di mana kesalahan yang lebih besar memiliki bobot lebih tinggi. Oleh karena itu, semakin rendah nilai RMSE, semakin baik kinerja prediksi model. Sementara itu, *Mean Absolute Error* (MAE) menghitung rata-rata selisih absolut antara nilai aktual dan nilai prediksi, sehingga menjadi ukuran langsung terhadap akurasi prediksi.

Dalam penelitian ini, RMSE dan MAE dipilih sebagai metrik untuk menilai tingkat akurasi keseluruhan dari hasil prediksi. Selain itu, koefisien korelasi digunakan untuk mengevaluasi kekuatan hubungan linear antara nilai aktual dan nilai prediksi. Nilai korelasi yang tinggi (mendekati 1) menunjukkan bahwa model mampu menangkap pola tren dalam data dengan baik, sedangkan nilai korelasi yang rendah mengindikasikan bahwa kemampuan prediksi model kurang optimal. Analisis korelasi ini diterapkan untuk menentukan sejauh mana model dapat menangkap tren dan pola musiman dalam dataset.

Row No.	Last Tanggal	predictionSALAMA	SALAMAN	predictionBOROBUDUR	BOROBUDUR	predictionNGLUWAR	NGLUWAR	predictionSALAM...
75	Mar 31, 2022	210.340	210	7240.254	6900	430.645	438	141.838
74	Feb 28, 2022	219.600	222	6509.367	6510	548.678	580	1264.416
106	Oct 31, 2024	667.174	667	5766.411	5832.300	520.167	286.410	4861.863
95	Feb 28, 2023	138.908	141	5569.806	5626	530.734	514	3005.634
87	Apr 30, 2022	195.113	210	5519.963	5250	587.170	580	1381.197
76	Mar 31, 2023	619.766	621	4645.722	4672	657.175	661	5941.964
88	Apr 30, 2023	146.320	146	4716.359	4672	634.514	655	1883.803
54	Jan 30, 2020	-3.131	0	4646.412	4462	101.041	20	251.183
89	May 31, 2023	889.422	895	4625.086	4684	634.231	645	1390.150
83	Nov 30, 2022	317.008	317	3912.542	3803	812.536	783	673.680
85	Jan 31, 2023	19.051	24	3638.712	3350	728.003	732	2182.351
73	Jan 31, 2022	123.635	140	3355.553	3250	189.964	143.500	1125.188
72	Dec 31, 2021	140.569	135	3031.105	3082	127.058	182	2602.708
100	Apr 30, 2024	197.685	198	3006.234	3063	604.951	688.680	2910.755
99	May 31, 2024	149.533	149	3035.908	2940	603.867	668	2440.722
77	May 31, 2022	635.024	635	3047.449	2870	721.155	700	1954.840
51	Mar 31, 2020	-3.131	0	842.809	2142	36.766	28	173.891
98	Feb 28, 2024	121.885	122	3011.085	2752	359.946	751.200	782.583

Gambar 5 Keluaran Data dari Model Prediksi

Gambar diatas menunjukkan hasil keluaran dataset yang diperoleh dari percobaan model yang dikembangkan. Permodelan ini dilakukan dengan menggunakan dua dataset yang berbeda, yaitu data produksi tanaman cabai per bulan per kecamatan di Kabupaten Magelang

sejak tahun 2015 hingga 2024 yang dikategorikan ke dalam dua kelompok utama, yaitu dataset produksi untuk tanaman Cabai Besar dan dataset produksi untuk tanaman Cabai Rawit. Untuk menentukan arsitektur *Neural Network* yang optimal dalam memprediksi produksi cabai, dilakukan pengujian terhadap beberapa konfigurasi model dengan kedua dataset tersebut. Evaluasi model dilakukan berdasarkan tiga metrik utama, yaitu *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan korelasi. Selain itu, standar deviasi dari masing-masing metrik juga dianalisis untuk menilai konsistensi prediksi di berbagai wilayah.

Pada tahap awal, jumlah siklus dalam proses pelatihan model ditetapkan sebanyak 500 siklus sebagai nilai awal. Pemilihan jumlah ini bertujuan untuk mengidentifikasi arsitektur model yang memberikan performa terbaik, sebelum dilakukan penyetelan lebih lanjut untuk menentukan jumlah iterasi pelatihan yang optimal. Dari beberapa percobaan konfigurasi arsitektur model prediksi, diperoleh model dengan performa terbaik sebagaimana ditampilkan pada Tabel 1 untuk performa model prediksi produksi Cabai Besar dan Tabel 2 untuk performa model prediksi produksi Cabai Rawit.

Arsitektur	RMSE	MAE	Corelation
12 – 5 – 1	712.390 +/- 1089.775	478.793 +/- 750.158	0.863 +/- 0.085
12 – 10 – 1	696.018 +/- 1076.514	449.423 +/- 706.371	0.866 +/- 0.089
12 – 15 – 1	744.401 +/- 1178.456	541.118 +/- 910.541	0.871 +/- 0.073
12 – 20 – 1	729.713 +/- 1183.202	499.429 +/- 861.908	0.870 +/- 0.071
12 – 25 – 1	691.381 +/- 1052.801	442.387 +/- 672.019	0.866 +/- 0.090
12 – 30 – 1	752.578 +/- 1248.757	504.606 +/- 846.078	0.866 +/- 0.077

**Tabel 1 Performa Model Prediksi Produksi Cabai Besar dengan Berbagai Arsitektur Model**

Arsitektur	RMSE	MAE	Corelation
12 – 5 – 1	573.196 +/- 619.136	362.707 +/- 370.903	0.872 +/- 0.100
12 – 10 – 1	571.655 +/- 623.674	375.145 +/- 397.583	0.879 +/- 0.092
12 – 15 – 1	570.121 +/- 602.069	354.108 +/- 347.987	0.877 +/- 0.093
12 – 20 – 1	575.730 +/- 616.592	353.836 +/- 369.165	0.881 +/- 0.091
12 – 25 – 1	603.467 +/- 634.124	401.095 +/- 390.749	0.876 +/- 0.090
12 – 30 – 1	598.651 +/- 671.945	391.153 +/- 451.266	0.874 +/- 0.098

**Tabel 1 Performa Model Prediksi Produksi Cabai Rawit dengan Berbagai Arsitektur Model**

Dari kedua tabel di atas, dapat disimpulkan bahwa untuk *Dataset Cabai Besar*, arsitektur terbaik adalah 12 – 25 – 1, dengan nilai RMSE terendah yaitu 691.381 dan MAE terendah 442.387, serta korelasi yang stabil sebesar 0.866. Selain itu, arsitektur ini memiliki standar deviasi terendah sebesar  $\pm 1052.801$  untuk RMSE dan  $\pm 672.019$  untuk MAE, yang menunjukkan bahwa hasil prediksi lebih konsisten di seluruh kecamatan. Sementara itu, arsitektur yang lebih kompleks, 12 – 30 – 1, tidak meningkatkan akurasi dan justru menghasilkan hasil prediksi yang lebih tidak menentu, menunjukkan bahwa model menjadi kurang mampu memprediksi data dengan baik. Sedangkan untuk *Dataset Cabai Rawit*, arsitektur terbaik adalah 12 – 15 – 1, dengan RMSE terendah sebesar 570.121, MAE terendah sebesar 354.108, serta korelasi yang tinggi hingga 0.877. Selain itu, arsitektur ini juga memiliki standar deviasi terendah sebesar  $\pm 602.069$  untuk RMSE dan  $\pm 347.987$  untuk MAE, yang berarti hasil prediksinya lebih stabil di semua kecamatan. Meskipun arsitektur 12 – 20 – 1 menghasilkan korelasi tertinggi senilai 0.881, nilai RMSE-nya juga lebih tinggi di angka 575.730, sehingga 12 – 15 – 1 memberikan keseimbangan terbaik antara tingkat kesalahan dan kemampuan menangkap pola dari data.

Setelah memilih arsitektur dengan performa terbaik, berbagai jumlah siklus pelatihan diuji untuk melihat pengaruhnya terhadap kinerja model. Untuk menentukan jumlah siklus pelatihan yang optimal, arsitektur yang telah dipilih dilatih dengan 500 hingga 3500 siklus, dengan peningkatan 500 siklus di setiap percobaan. Hasil dari percobaan ini menghasilkan model dengan performa yang ditampilkan pada tabel di bawah ini.

Training Cycles	RMSE	MAE	Corelation
500	691.381 +/- 1052.801	442.387 +/- 672.019	0.866 +/- 0.090
1000	514.253 +/- 776.690	360.769 +/- 569.624	0.926 +/- 0.060
1500	467.210 +/- 711.916	345.883 +/- 578.036	0.945 +/- 0.051
2000	406.815 +/- 600.032	300.452 +/- 494.166	0.954 +/- 0.048
2500	378.722 +/- 574.293	273.514 +/- 454.522	0.960 +/- 0.040
3000	353.592 +/- 523.842	252.915 +/- 407.839	0.965 +/- 0.036
3500	324.300 +/- 456.411	229.006 +/- 346.240	0.968 +/- 0.034

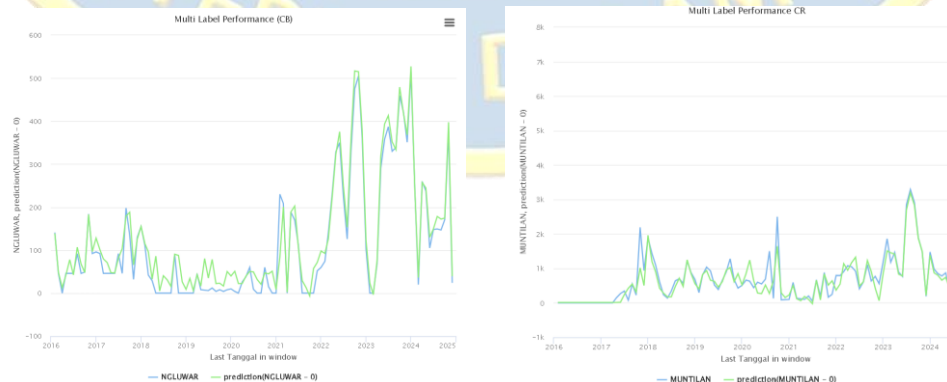
**Tabel 3 Performa Model Prediksi Produksi Cabai Besar dengan Arsitektur 12-25-1**

Training Cycles	RMSE	MAE	Corelation
500	570.121 +/- 602.069	354.108 +/- 347.987	0.877 +/- 0.093
1000	469.055 +/- 567.829	282.842 +/- 306.651	0.924 +/- 0.062
1500	419.554 +/- 544.795	259.503 +/- 311.016	0.944 +/- 0.049
2000	392.600 +/- 521.389	250.121 +/- 313.312	0.954 +/- 0.042
2500	364.357 +/- 485.683	232.750 +/- 282.707	0.961 +/- 0.035
3000	342.878 +/- 461.384	218.383 +/- 262.895	0.965 +/- 0.033
3500	326.698 +/- 442.639	206.694 +/- 245.439	0.969 +/- 0.029

**Tabel 4 Performa Model Prediksi Produksi Cabai Rawit dengan Arsitektur 12-15-1**

Hasil menunjukkan bahwa menambah jumlah siklus pelatihan dapat meningkatkan performa model dan akurasi prediksi, yang terlihat dari penurunan nilai RMSE dan MAE serta peningkatan korelasi. Meskipun model yang dilatih hingga 3500 siklus mencapai akurasi tertinggi, peningkatannya semakin kecil di setiap kenaikan siklus. Penambahan siklus pelatihan lebih lanjut tetap dapat menyempurnakan model namun memberikan peningkatan kinerja yang tidak drastis. Selain itu, semakin banyak siklus pelatihan yang digunakan, semakin lama waktu komputasi yang dibutuhkan. Oleh karena itu, pemilihan jumlah siklus yang optimal harus mempertimbangkan keseimbangan antara peningkatan akurasi dan efisiensi komputasi.

### 3.5. Pembahasan Hasil



**Gambar 6 Grafik Visualisasi Perbandingan Nilai Prediksi dan Sebenarnya**

Berdasarkan visualisasi data di atas, hasil prediksi mampu memberikan estimasi yang cukup akurat dan dapat mengikuti pola naik-turun produksi musiman sesuai dengan data aktual. Namun, dari analisis statistik hasil prediksi, ditemukan bahwa model masih memiliki kelemahan dalam memprediksi produksi tanaman pertanian, khususnya dalam kasus ini untuk memperkirakan produksi cabai. Salah satu kelemahan yang teridentifikasi adalah munculnya nilai prediksi negatif, yang secara logis tidak mungkin terjadi dalam produksi pertanian. Seharusnya, nilai terendah yang dihasilkan adalah 0, yang berarti pada periode tersebut tidak ada produksi sama sekali. Untuk mengatasi masalah ini, semua nilai prediksi negatif dapat dikonversi menjadi 0. Dengan ini hasil prediksi diharapkan menjadi lebih realistis dan sesuai dengan kondisi nyata di lapangan, sehingga meningkatkan keandalan model dalam mendukung pengambilan keputusan oleh Dinas Pertanian dan Pangan.

Model prediksi dalam penelitian ini dikembangkan menggunakan algoritma *Artificial Neural Network* dengan metode *Backpropagation* untuk membantu Dinas Pertanian dan Pangan dalam memprediksi produksi cabai di Kabupaten Magelang. Penggunaan sistem prediksi ini dapat memberikan kemudahan bagi Dinas Pertanian dan Pangan Kabupaten Magelang, dimana dengan adanya prediksi ini dinas pertanian akan dengan mudah mengetahui estimasi besaran produksi cabai yang diprediksi dengan terstruktur berdasarkan tren musiman tahunan dari data produksi masa lalu pada setiap daerah sehingga menghasilkan besaran prediksi yang cukup akurat.

Berdasarkan berbagai wawancara yang dilakukan, prediksi produksi cabai dalam penelitian ini dapat dimanfaatkan untuk membantu pengambilan keputusan dalam *Stabilisasi Pasokan dan Harga Pangan* (SPHP) dengan memberikan estimasi produksi cabai di masa mendatang. Dengan estimasi ini, instansi terkait dapat merencanakan langkah-langkah strategis dan memperkirakan stok lebih awal, sehingga pengelolaan pasokan serta stabilisasi harga dapat dilakukan secara lebih efektif.

Di luar fokus utama penelitian ini, pemanfaatan prediksi produksi cabai juga memberikan dampak positif lainnya. Hasil prediksi yang masuk akal dapat dijadikan sebagai target produksi, yang secara tidak langsung mendorong penyuluh pertanian dalam membina petani. Dengan adanya angka prediksi sebagai acuan, petani lebih termotivasi untuk meningkatkan produksi guna mencapai target yang telah diperkirakan. Hal ini berbeda dibandingkan dengan kondisi tanpa prediksi, di mana petani cenderung menghasilkan cabai dengan jumlah seadanya. Dampak ini berpotensi meningkatkan produktivitas pertanian secara keseluruhan.

Selain itu, sistem prediksi yang dikembangkan juga dapat membantu pelaksanaan tugas administrasi Dinas Pertanian dan Pangan, khususnya dalam monitoring dan pelaporan produksi pertanian setiap kecamatan di Kabupaten Magelang. Berdasarkan wawancara dengan penyuluh pertanian, pernah ditemukan kasus di mana laporan daerah menunjukkan tidak adanya produksi cabai padahal secara nyata terdapat banyak lahan yang menanam cabai. Penyuluh biasanya memperkirakan produksi berdasarkan luas lahan, produktivitas tanaman, dan frekuensi panen untuk mengatasi permasalahan tersebut.

Dengan adanya sistem prediksi ini, metode estimasi tersebut dapat disempurnakan dengan mempertimbangkan atribut-atribut yang serupa, seperti luas lahan pertanian, tingkat produktivitas, serta profitabilitas tanaman. Hal ini akan mendukung administrasi publik dalam bidang pertanian, terutama dalam memastikan akurasi pelaporan produksi pertanian. Selain itu, model prediksi juga dapat berfungsi sebagai alat validasi untuk mendeteksi perbedaan signifikan antara hasil prediksi dan data produksi yang dilaporkan. Jika ditemukan selisih yang mencolok, pejabat terkait dapat segera melakukan analisis lebih lanjut guna mengidentifikasi penyebab perbedaan tersebut dan mengambil tindakan yang diperlukan.

Sistem proyeksi berbasis teknologi ini memberikan manfaat utama bagi Dinas Pertanian dan Pangan dalam menjalankan tugas dan tanggungjawabnya. Dengan model prediksi yang dikembangkan, instansi dapat melakukan pengambilan keputusan berbasis data, sehingga perencanaan dan pengelolaan sektor pertanian menjadi lebih optimal. Prediksi yang akurat memungkinkan dinas untuk mengantisipasi kebutuhan pasokan, mengelola distribusi, serta mengurangi risiko fluktuasi harga yang dapat berdampak pada stabilitas pangan.

Selain itu, model prediksi ini juga mendukung tugas administratif dinas dalam monitoring dan pelaporan produksi pertanian. Dengan adanya sistem yang mampu memproyeksikan hasil produksi, potensi ketidaksesuaian data dapat segera terdeteksi, sehingga dinas dapat melakukan validasi lebih cepat dan mengambil Langkah penanganan yang diperlukan. Hal ini meningkatkan akurasi data pertanian yang digunakan sebagai dasar dalam penyusunan kebijakan.

### **3.6. Diskusi Temuan Utama Penelitian**

Penelitian ini menemukan bahwa metode Artificial Neural Network (ANN) dengan algoritma Backpropagation sangat efektif dalam memprediksi produksi cabai di Kabupaten Magelang, baik untuk cabai besar maupun cabai rawit. Model ANN yang dibangun melalui preprocessing dan pelatihan dengan berbagai arsitektur, menunjukkan hasil prediksi dengan korelasi yang sangat tinggi terhadap data aktual. Model terbaik untuk cabai besar menggunakan arsitektur 12–25–1 dengan RMSE sebesar 324.300, MAE 229.006, dan korelasi 0,968. Sedangkan untuk cabai rawit, arsitektur terbaik adalah 12–15–1 dengan RMSE 326.698, MAE 206.694, dan korelasi 0,969. Nilai korelasi yang mendekati 1 menunjukkan bahwa model sangat akurat dalam memetakan pola tren produksi historis.

Temuan ini sejalan dengan penelitian Salis et al. (2024) yang menunjukkan bahwa algoritma Backpropagation cukup efektif dalam memprediksi jumlah siswa SMA dengan akurasi mencapai 87,5%, menggunakan arsitektur 4–25–1. Sama halnya dengan penelitian Sari et al. (2024) yang juga mendukung efektivitas metode Backpropagation dalam prediksi harga pasar teh dengan akurasi 99%. Temuan ini memperkuat hasil penelitian tersebut karena ANN dengan metode Backpropagation terbukti andal digunakan dalam domain prediksi berbasis time series, baik pada sektor pendidikan, komoditas pasar, maupun pertanian.

Lebih lanjut, model prediksi dalam penelitian ini juga menunjukkan kontribusi strategis dalam mendukung kebijakan Stabilisasi Pasokan dan Harga Pangan (SPHP) karena mampu menyediakan estimasi produksi yang dapat digunakan pemerintah untuk memetakan stok, mengantisipasi lonjakan harga, serta merencanakan intervensi kebijakan lebih awal. Temuan ini memberikan nilai praktis yang tidak hanya terbatas pada aspek teknis prediksi, tetapi juga implikatif terhadap pengambilan keputusan publik. Dengan demikian, temuan dalam penelitian ini tidak hanya konsisten dengan berbagai studi terdahulu yang menggunakan metode ANN-Backpropagation, tetapi juga memperluas kontribusi ke arah penguatan kebijakan publik berbasis data dalam sektor pertanian

### **3.7. Diskusi Temuan Menarik Lainnya**

Di luar fokus utama penelitian yang berkaitan dengan dukungan terhadap kegiatan stabilisasi pasokan dan harga pangan, ditemukan beberapa temuan menarik lainnya yang berpotensi memberikan manfaat tambahan dalam konteks pertanian daerah. Salah satu temuan tersebut adalah bahwa hasil prediksi produksi yang dihasilkan oleh model ANN secara tidak langsung membentuk persepsi target produksi di kalangan petani. Besaran produksi yang diprediksi oleh model justru dipahami sebagai sasaran yang perlu dicapai, sehingga mendorong

petani untuk berusaha memenuhi "target" produksi tersebut. Hal ini berbeda dengan situasi sebelumnya, di mana tanpa adanya acuan target yang jelas, petani cenderung memanen secara seadanya tanpa strategi intensifikasi yang terarah. Dengan demikian, model prediksi juga berkontribusi dalam mendorong peningkatan produktivitas pertanian melalui aspek psikologis dan motivasional.

Selain itu, model prediksi juga berfungsi sebagai alat validasi yang bermanfaat bagi instansi pemerintah dalam mendeteksi ketidaksesuaian data. Ketika terdapat perbedaan signifikan antara hasil prediksi dan data produksi aktual yang dilaporkan, hal tersebut dapat menjadi sinyal awal adanya potensi permasalahan, baik karena kesalahan pencatatan, perubahan kondisi lapangan, atau faktor eksternal lainnya. Dengan mengidentifikasi selisih tersebut secara dini, pejabat teknis dapat melakukan investigasi lebih lanjut guna menentukan penyebabnya serta mengambil langkah korektif jika diperlukan.

#### IV. KESIMPULAN

Penelitian ini menunjukkan bahwa metode *Artificial Neural Network* (ANN) dengan algoritma *Backpropagation* cocok digunakan untuk memprediksi produksi cabai di Kabupaten Magelang. Model ANN dikembangkan melalui proses preprocessing data dan pelatihan jaringan menggunakan berbagai arsitektur dan jumlah siklus pelatihan untuk memperoleh konfigurasi terbaik. Evaluasi dilakukan menggunakan metrik statistik seperti *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan korelasi antara hasil prediksi dan data aktual.

Model prediksi terbaik untuk cabai besar menggunakan arsitektur jaringan 12–25–1 dengan 3500 siklus pelatihan, menghasilkan:

RMSE = 324.300; MAE = 229.006; Korelasi = 0,968

Sedangkan model terbaik untuk cabai rawit menggunakan arsitektur 12–15–1 dengan jumlah siklus yang sama, menghasilkan:

RMSE = 326.698; MAE = 206.694; Korelasi = 0,969

Nilai korelasi yang sangat mendekati 1 menunjukkan bahwa pola tren produksi yang diprediksi oleh model sangat akurat jika dibandingkan dengan data aktual. Hasil prediksi ini dapat dimanfaatkan sebagai alat bantu pengambilan keputusan oleh pemerintah daerah, khususnya dalam mendukung kebijakan Stabilisasi Pasokan dan Harga Pangan (SPHP) melalui estimasi produksi cabai di masa mendatang. Dengan estimasi ini, instansi terkait dapat memperkirakan stok, harga dan memungkinkan merencanakan langkah strategis lebih awal.

**Keterbatasan Penelitian.** Penelitian ini memiliki beberapa keterbatasan pada aspek waktu pelaksanaan dan ketersediaan data. Model prediksi yang dikembangkan hanya menggunakan satu variabel, yaitu besaran produksi tanaman cabai selama periode 2015 hingga 2025. Penggunaan variabel tunggal ini membatasi kemampuan model dalam menangkap dinamika yang mempengaruhi produksi secara lebih kompleks. Model prediksi diperkirakan akan memberikan hasil yang lebih akurat apabila dilatih dengan data yang lebih lengkap, mencakup variabel pendukung seperti curah hujan, harga cabai, luas lahan tanam, produktivitas, dan provitas. Selain itu, jumlah data historis yang lebih panjang dan berkualitas juga sangat penting untuk mengembangkan arsitektur model yang lebih stabil dan representatif terhadap kondisi lapangan. Keterbatasan ini menjadi catatan penting bagi penelitian lanjutan agar pengembangan model prediksi dapat dilakukan secara lebih menyeluruh dan aplikatif.

**Arah Masa Depan Penelitian (*future work*).** Penulis menyadari bahwa penelitian ini merupakan langkah awal dalam pengembangan model prediksi produksi cabai untuk mendukung pengambilan keputusan di lingkungan pemerintahan daerah. Oleh karena itu,

penelitian selanjutnya disarankan untuk menggunakan data yang lebih komprehensif, dengan penambahan atribut atau variabel yang relevan, seperti luas lahan tanam, curah hujan, jenis varietas, serta penggunaan sarana produksi pertanian. Penambahan variabel tersebut diharapkan dapat meningkatkan akurasi dan relevansi model dalam konteks perencanaan kebijakan. Selain itu, model prediksi yang telah dibangun juga berpotensi dikembangkan lebih lanjut menjadi sebuah aplikasi berbasis digital dengan antarmuka pengguna yang menampilkan hasil prediksi secara real-time. Pengembangan ini diharapkan dapat memberikan kontribusi lebih nyata bagi Dinas Pertanian dan Pangan Kabupaten Magelang dalam menjalankan fungsi monitoring dan pengambilan keputusan strategis

## V. UCAPAN TERIMA KASIH

Ucapan terima kasih penulis sampaikan kepada seluruh komponen Dinas Pertanian dan Pangan Kabupaten Magelang, termasuk Unit Pelaksana Teknis Daerah (UPTD) yang telah memberikan dukungan data, informasi, dan fasilitasi selama proses penelitian berlangsung. Penulis juga mengucapkan terima kasih kepada seluruh civitas akademika Institut Pemerintahan Dalam Negeri (IPDN) yang ikut memberikan arahan, bimbingan ilmiah, dan motivasi selama penyusunan karya ilmiah ini. Ucapan terima kasih juga ditujukan kepada semua pihak yang tidak dapat disebutkan satu per satu namun telah memberikan bantuan moril maupun materil dalam penyelesaian penelitian ini.

## VI. DAFTAR PUSTAKA

- Asteris, P. G., Kolovos, K. G., Douvika, M. G., & Roinos, K. (2016). Prediction of self-compacting concrete strength using artificial neural networks. *European Journal of Environmental and Civil Engineering*, 20, s102–s122. <https://doi.org/10.1080/19648189.2016.1246693>
- Badan Pusat Statistik Kabupaten Magelang. (2017). *Produksi Tanaman Sayur-Sayuran Menurut Kecamatan di Kabupaten Magelang (Kuintal), 2015-2017*. <https://magelangkab.bps.go.id/id/statistics-table/2/MjA0IzI=/produksi-tanaman-sayur-sayuran-menurut-kecamatan-di-kabupaten-magelang--kuintal-.html>
- Fahle, S., Prinz, C., & Kuhlenkötter, B. (2020). Systematic review on machine learning (ML) methods for manufacturing processes - Identifying artificial intelligence (AI) methods for field application. *Procedia CIRP*, 93, 413–418. <https://doi.org/10.1016/j.procir.2020.04.109>
- Halim, A. (2020). Pemberdayaan Petani Sawah Melalui Kegiatan Pembinaan dan Pendampingan di Kabupaten Maros. *Jurnal Pallangga Praja*, 2(2), 167–179. <https://doi.org/10.61076/jpp.v2i2.1660>
- Idris, M., Institut, P., Dalam, P., Kampus, N., & Selatan, S. (2022). Pemberdayaan Petani Di Desa Mattanete Bua Kabupaten Bone Provinsi Sulawesi Selatan. *Jurnal Pallangga Praja*, 4(1). <https://doi.org/10.61076/jpp.v4i1.2638>
- Kurani, A., Doshi, P., Vakharia, A., & Shah, M. (2023). A Comprehensive Comparative Study of Artificial Neural Network (ANN) and Support Vector Machines (SVM) on Stock Forecasting. In *Annals of Data Science* (Vol. 10, Issue 1, pp. 183–208). Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1007/s40745-021-00344-x>
- Ma'ruf, M., Ikbaluddin, I., Suropto, S., & Abdurrohman, A. (2021). Pengembangan Kapasitas (Capacity Building) Usaha Kecil dan Menengah Bidang Pertanian Di Kecamatan Rancabungur Kabupaten Bogor. *J-3P (Jurnal Pembangunan Pemberdayaan Pemerintahan)*, 16–32. <https://doi.org/10.33701/j-3p.v6i1.1512>

- Marwati, F., & Fauzi, R. (2024). Prediksi Penyakit Diabetes Melitus Menggunakan Jaringan Syaraf Tiruan Dengan Metode Backpropagation. *Jurnal Informatika Utama (JITU)*, 1, 26–34. <https://doi.org/10.55903/jitu.v2i1.163>
- Maryani, D., & Nainggolan, R. R. E. (2019). *Pemberdayaan Masyarakat*. Deepublish.
- Mohamad, E. T., Armaghani, D. J., Momeni, E., Yazdavar, A. H., & Ebrahimi, M. (2018). Rock strength estimation: a PSO-based BP approach. *Neural Computing and Applications*, 30(5), 1635–1646. <https://doi.org/10.1007/s00521-016-2728-3>
- Moleong, L. J. (2007). *Metodologi Penelitian Kualitatif* (20th ed.). PT Remaja Rosdakarya.
- Purmala, Y. A. (2021). Penerapan machine learning dalam meningkatkan produktivitas di industri manufaktur: Tinjauan literatur (Implementation of machine learning to increase productivity in the manufacturing industry: A literature review). *Operations Excellence: Journal of Applied Industrial Engineering*, 13(2), 267–275. <https://doi.org/doi.org/10.22441/oe.2021.v13.i2.026>
- Putri, D. R., Swanjaya, D., & Farida, I. N. (2024). Model Integrasi Algoritma Spectral Clustering Dan Backpropagation Pada Prediksi Penjualan Barang. *Jurnal Nusantara of Engineering*, 7(1), 59–66. <https://doi.org/https://doi.org/10.29407/noe.v7i01.20885>
- Sakina, E., & Mirza, A. H. (2024). Prediksi Hasil Produksi Ikan Lele Menggunakan Machine Learning (Studi Kasus Dinas Perikanan Kabupaten Muara Enim). *Jurnal Informatika Sains Dan Teknologi (INSTEK)*, 9(1), 55–64. <https://doi.org/https://doi.org/10.24252/instek.v9i1.46406>
- Salis, R., Windarto, A. P., & Suhendro, D. (2024). Implementasi Algoritma Backpropagation Untuk Prediksi Jumlah Siswa SMA. *Jurnal Media Informatika Budidarma*, 8(3), 1597–1608. <https://doi.org/10.30865/mib.v8i3.7774>
- Sari, D. M., Ikhsan, M., & Putri, R. A. (2024). Jaringan Syaraf Tiruan Prediksi Harga Pasar Teh Menggunakan Metode Backpropagation. *Jurnal Sistem Informasi Bisnis (JUNSIBI)*, 5(1), 109–121. <https://doi.org/10.55122/junsibi.v5i1.1221>
- Surya, A. D., Sapriyaldi, M., Wanto, A., Windarto, A. P., & Damanik, I. S. (2021). Komparasi Algoritma Machine Learning untuk Penentuan Performance Terbaik Pada Prediksi Produksi Tanaman Jahe di Indonesia. In *Seminar Nasional Ilmu Sosial dan Teknologi (SANISTEK)* (Vol. 1, pp. 276–284).
- Tim Penyusun BPS Kabupaten Magelang. (2025). *Kabupaten Magelang Dalam Angka 2025* (L. Kurniati, J. Prasetyo, & E. H. Yonanda, Eds.; 1st ed., Vol. 47). Badan Pusat Statistik Kabupaten Magelang. <https://magelangkab.bps.go.id/id/publication/2025/02/28/281d0795d4de4ee687252e54/kabupaten-magelang-dalam-angka-2025.html>