

Implementasi Artificial Neural Network Pada Kasus Regresi Linear Berganda Untuk Memprediksi Jumlah Pakan Ayam Petelur

ALI ASGAR ZAINAL ABIDIN¹, KUSRINI², FERRY WAHYU WIBOWO³

¹²³Magister Teknik Informatika,

Universitas Amikom Yogyakarta

Email: aliasgarzainalabidin@students.amikom.ac.id, kusrini@amikom.ac.id,
ferry.w@amikom.ac.id

ABSTRAK

Produksi telur ayam petelur adalah bagian penting dalam industri peternakan dan berperan besar dalam memenuhi kebutuhan masyarakat akan telur sebagai sumber makanan. Penelitian ini menggunakan algoritma Jaringan Saraf Tiruan (JST), yang sering digunakan untuk memprediksi data, untuk melakukan prediksi jumlah pakan yang dibutuhkan oleh ayam petelur. Penelitian ini bukan tentang hasil prediksi konkret, tetapi lebih tentang evaluasi kemampuan algoritma JST dalam melakukan prediksi berdasarkan *dataset* yang diperoleh dari sumber Kaggle. Dalam penelitian ini, berbagai model arsitektur jaringan neural telah dieksplorasi, termasuk model dengan struktur 5-30-1, 5-40-1, 5-50-1, dan 5-60-1. Setiap model telah dilatih dan diuji, dan hasilnya menunjukkan bahwa model arsitektur terbaik adalah yang memiliki struktur 5-40-1, dengan tingkat kinerja (MAPE) terendah sekitar 4.04 dan RMSE sebesar 6.71, yang merupakan tingkat kesalahan terendah dibandingkan dengan enam model lainnya. Ini mengindikasikan bahwa model tersebut dapat digunakan dengan baik untuk melakukan prediksi jumlah pakan yang dibutuhkan oleh ayam petelur.

Kata kunci : Jaringan Saraf Tiruan, *Performance*, Pakan Ayam Petelur

I. PENDAHULUAN

Telur merupakan sumber gizi dan protein yang penting bagi tubuh manusia (Budiarto et al., 2020). Selain itu, telur juga dikenal sebagai makanan yang kaya gizi dengan harga yang terjangkau jika dibandingkan dengan sumber protein

lainnya, dan selalu mudah didapatkan (ARTINI, 2017). Kandungan nutrisi penting seperti protein, lemak, vitamin, dan mineral yang dibutuhkan oleh manusia terdapat dalam telur (Frisca Siahaan, 2017). Beberapa penelitian sebelumnya digunakan sebagai rujukan pada penelitian ini adalah penelitian terkait produktivitas bahan pangan juga pernah dilakukan dengan menggunakan jaringan syaraf tiruan sebagai model untuk memprediksi produktivitas pada padi (Gandhi Ramadhona, Budi Darma Setiawan, 2018), prediksi hasil produksi kelapa sawit (Komariah et al., n.d.) dan penelitian produksi ayam petelur berdasarkan provinsi di Indonesia dengan tingkat akurasi yang diperoleh sebesar 96.88% (Pamungkas et al., 2022). Produktivitas ternak yang ditingkatkan dapat berkontribusi pada peningkatan produksi telur. Hasil produksi telur dapat dipengaruhi oleh jumlah pakan yang diberikan kepada ayam petelur dalam sehari; semakin sedikit pakan yang dibutuhkan, semakin besar hasil produksi telurnya.

Pentingnya melakukan prediksi terhadap jumlah pakan yang diperlukan oleh ayam petelur agar mereka dapat menghasilkan telur telah diakui. Algoritma *Machine Learning* adalah salah satu metode Jaringan Saraf Tiruan (JST) yang umumnya digunakan untuk memprediksi data (Wibawa, 2017)(Muhamad et al., 2022)(Sudarsono, 2016). Namun, penelitian ini tidak fokus pada prediksi kebutuhan harian pakan ayam petelur. Sebaliknya, penelitian ini bertujuan mengevaluasi kemampuan algoritma JST untuk membuat prediksi berdasarkan *dataset* yang diperoleh dari *Kaggle*. Dengan menggunakan arsitektur dan parameter model yang telah ditentukan sebelumnya, penelitian ini bertujuan menguji akurasi atau optimasi algoritma JST. Evaluasi matriks yang akan digunakan yakni MAPE dan RMSE (Adriono et al., 2022).

II. METODE PENELITIAN

A. Metode Pengumpulan Data

Cara pengumpulan data yang diterapkan dalam penelitian ini adalah metode pengumpulan data berupa data kuantitatif, yang diperoleh dari *dataset* ayam petelur yang tersedia di situs web Kaggle. *Dataset* ini terdiri dari 1000 baris data dengan 16 parameter, seperti yang tercantum dalam **Tabel 1** berikut ini:

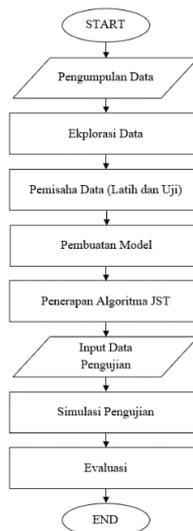
Tabel 1 Kebutuhan Pakan Ayam Petelur Per Hari

GallusID	Gallus Breed	Day	Age (week)	Gallus Weight (gr)	Gallus EggColor	Gallus Egg Weight (gr)	Amount OfFeed (gr)	Eggs PerDay	Gallus Comb Type	Sun Light Exposure (hour)	Gallus Class	Gallus Leg Shanks Color	Gallus Beak Color	Gallus Ear Lobes Color	Gallus Plumage
Marans1	Marans	1	883	3000	Brown	41.19	114	1	Single	7	Continental	White	White	NULL	Blue Copper
Marans1	Marans	2	883	3000	Brown	41.19	114	1	Single	7	Continental	White	White	NULL	Blue Copper
Marans1	Marans	3	883	3000	Brown	41.19	114	1	Single	7	Continental	White	White	NULL	Blue Copper
Marans1	Marans	4	883	3000	Brown	41.19	114	1	Single	7	Continental	White	White	NULL	Blue Copper
Marans1	Marans	5	883	3000	Brown	41.19	114	1	Single	7	Continental	White	White	NULL	Blue Copper

Berdasarkan **Tabel 1** di atas, parameter-parameter yang akan digunakan sebagai input dalam penelitian ini adalah: GallusBreed, Age, GallusWeight, GallusCombType, SunLightExposure, GallusClass, GallusLegShanksColor, GallusBeakColor, GallusEarLobesColor, dan GallusPlumage. Sedangkan parameter yang akan digunakan sebagai target adalah: AmountOfFeed. Parameter-parameter lainnya akan diabaikan karena dianggap kurang relevan dengan parameter target yang akan diukur.

B. Alur Penelitian

Tahapan-tahapan yang dilakukan penelitian ini dapat dilihat pada **Gambar 1** berikut ini:



Berdasarkan **Gambar 1** di atas, tahapan awal dalam penelitian ini adalah mengumpulkan *dataset* penelitian (sesuai Tabel 1). Langkah berikutnya adalah

melakukan eksplorasi data, yang mencakup menghapus kolom yang tidak diperlukan, melakukan preparasi data seperti mengidentifikasi dan menghapus data duplikat, mengisi data yang kosong, mengubah data kategorikal menjadi data numerikal, dan melakukan normalisasi data. Setelah itu, *dataset* penelitian dipisahkan menjadi dua kelompok, yaitu data pelatihan dan data pengujian.

Selanjutnya, data pelatihan yang sudah dinormalisasi digunakan untuk membuat beberapa model arsitektur jaringan saraf tiruan menggunakan bahasa pemrograman Python. Model ini terdiri dari tiga lapisan, yaitu lapisan input, lapisan tersembunyi, dan lapisan output. Tahap berikutnya adalah menginisialisasi parameter jaringan berdasarkan fungsi pelatihan yang akan digunakan. Kemudian, dilakukan proses pelatihan dan hasilnya dimonitor.

Selanjutnya, dilakukan simulasi data uji berdasarkan hasil pelatihan. Setelah semua tahap selesai, langkah terakhir adalah melakukan evaluasi untuk menentukan model arsitektur terbaik berdasarkan kinerja yang diukur, khususnya MAPE (*Mean Absolute Percentage Error*) yang paling rendah.

III. HASIL DAN PEMBAHASAN

A. Preparasi dan Eksplorasi Data

Setelah mendapatkan *dataset*, langkah awal yang perlu dilakukan adalah melakukan eksplorasi data dan persiapan data. Eksplorasi data dilakukan dengan tujuan untuk memahami *dataset* dan mencapai tujuan penelitian dengan lebih baik.

Selanjutnya, langkah persiapan data bertujuan untuk menghasilkan informasi yang akurat yang dapat digunakan dalam pengambilan keputusan. Proses persiapan data mencakup beberapa tindakan seperti membersihkan data dari anomali atau *outlier*, memeriksa adanya data duplikat, menghapus data duplikat jika ada, mengevaluasi data yang kosong, mengisi data yang kosong dengan nilai yang sesuai, menjalankan analisis deskriptif untuk memahami distribusi dan karakteristik data, melakukan normalisasi data agar memiliki skala yang seragam, dan mengubah tipe data kategorikal menjadi tipe data numerik jika diperlukan.

1. *Dropping* kolom pada tabel *dataset*

Dalam proses ini, dilakukan penghapusan kolom-kolom yang tidak

digunakan dalam tabel *dataset*. Beberapa kolom dihapus karena dianggap tidak memiliki relevansi dengan target yang akan diprediksi. Kolom-kolom yang dihapus meliputi: *GallusID*, *Day*, *GallusEggColor*, *GallusEggWeight*, dan *EggsPerDay*. Hasil dari proses ini dapat dilihat pada Tabel 2 berikut ini:

Tabel 2 Hasil Dropping Kolom Data

<i>Gallus Breed</i>	<i>Age (week)</i>	<i>Gallus Weight (gr)</i>	<i>Gallus Egg Weight (gr)</i>	<i>Amount OfFeed (gr)</i>	<i>Gallus Comb Type</i>	<i>Sun Light Exposure (hour)</i>	<i>Gallus Class</i>	<i>Gallus Leg Shanks Color</i>	<i>Gallus Beak Color</i>	<i>Gallus Ear Lobes Color</i>	<i>Gallus Plumage</i>
<i>Marans</i>	883	3000	41.19	114	<i>Single</i>	7	<i>Continental</i>	<i>White</i>	<i>White</i>	NULL	<i>Blue Copper</i>
<i>Marans</i>	883	3000	41.19	114	<i>Single</i>	7	<i>Continental</i>	<i>White</i>	<i>White</i>	NULL	<i>Blue Copper</i>
<i>Marans</i>	883	3000	41.19	114	<i>Single</i>	7	<i>Continental</i>	<i>White</i>	<i>White</i>	NULL	<i>Blue Copper</i>
<i>Marans</i>	883	3000	41.19	114	<i>Single</i>	7	<i>Continental</i>	<i>White</i>	<i>White</i>	NULL	<i>Blue Copper</i>
<i>Marans</i>	883	3000	41.19	114	<i>Single</i>	7	<i>Continental</i>	<i>White</i>	<i>White</i>	NULL	<i>Blue Copper</i>

2. Cek dan hapus data duplikat

Dalam tahapan ini, dilakukan pengecekan terhadap data duplikat dalam *dataset*. Total data awal sebelum dilakukan penghapusan data duplikat adalah sebanyak 1000 baris data, namun setelah proses penghapusan data duplikat, jumlah data menjadi hanya 190 baris data.

3. Cek dan isi data kosong

Dalam tahap ini, dilakukan pengecekan terhadap data yang memiliki nilai null atau NaN (*Not-a-Number*). Selanjutnya, data yang memiliki nilai null akan diisi dengan label seperti "missing".

4. Merubah data kategorikal menjadi numerikal

Dalam tahap ini, dilakukan transformasi data dari format kategorikal menjadi format numerik. Salah satu metode yang dapat digunakan untuk melakukan transformasi ini adalah metode *One-Hot Encoding*

5. Normalisasi data

Dalam tahap ini, dilakukan normalisasi data menggunakan metode Standarisasi Scalar. Normalisasi data merupakan proses yang penting untuk hasil atau kinerja dari model yang dibuat (Inggih Permana, 2022)(Whendasmoro &

Joseph, 2022).

B. Pemisahan Data *Training* dan *Testing*

Perbandingan data *training* dan *testing* yang digunakan dalam penelitian ini adalah sebesar 70:30, dengan ketentuan 70% data *training* dan 30% data *testing*. Dalam proses *splitting* data digunakan *library sklearn* yaitu *train_test_split*. *Library* ini melakukan pembagian data *training* dan data *testing* secara acak dengan *output* 30% data *testing* dan 70% data *training*. Umumnya, tidak ada panduan yang jelas tentang seberapa besar data yang harus digunakan untuk pelatihan dan pengujian (Joseph, 2022). Proses ini selalu dilakukan untuk mencegah algoritma pembelajaran mesin menghasilkan tipe *overfitting* yang dapat berperforma buruk pada data uji sebenarnya (Muraina, 2022)(Kahlout & Ekler, 2021).

C. Pembuatan Model

Pada tahap pembuatan model, digunakan *model Artificial Neural Network* (ANN) yakni *Multilayer Perceptron* (MLP) menggunakan *library keras*. Model ini dirancang dengan tiga lapisan, yaitu 1 lapisan *input*, 1 lapisan *hidden*, dan 1 lapisan *output*.

Pada lapisan *input*, terdapat masukan sebanyak 29 parameter dengan jumlah *neuron* pada input sebanyak 5 unit, digunakan kernel distribusi normal dan fungsi aktivasi *relu*. Sedangkan pada lapisan *hidden*, digunakan kernel distribusi normal dan fungsi aktivasi *tanh* jumlah neuronnya disesuaikan dengan beberapa nilai, yaitu: 30, 40, 50, dan 60 *neuron*. Lalu, pada lapisan *output*, menggunakan kernel normal tanpa fungsi aktivasi dan menghasilkan 1 *output*.

Penentuan jumlah neuron pada tiap lapisan ditentukan berdasarkan *output* yang diinginkan. Pada lapisan *input* digunakan jumlah *neuron* yang cenderung kecil untuk menghindari kompleksitas, komputasi yang besar dan masalah *overfitting*. Sedangkan pada lapisan *hidden* digunakan variasi *neuron* dengan tujuan mengetahui kombinasi *neuron* mana yang terbaik. Jumlah *neuron* yang digunakan pada lapisan *hidden* berperan penting dalam kinerja jaringan syaraf terutama dalam kasus masalah yang kompleks di mana akurasi dan kompleksitas waktu (Uzair & Jamil, 2020). Sedangkan pada lapisan *output* digunakan satu *neuron* sebagai hasil dari prediksi model yang dibuat.

Model ini dilakukan kompilasi menggunakan algoritma optimasi *adam* dengan fungsi loss *Mean Squared Error* (MSE). Sedangkan pada jumlah *batch* dan *epochs* yang digunakan yaitu 5 dan 50 secara berurutan. Jumlah *batch* 5 dan *epochs* 50 ini menjadi pilihan terbaik setelah dilakukan *Grid Search*.

D. Pelatihan dan Pengujian

Dalam tabel-tabel ini, Anda dapat menemukan nilai MAPE untuk setiap model, yang merupakan ukuran tingkat kesalahan relatif dalam prediksi. Semakin rendah nilai MAPE, semakin baik performa model dalam memprediksi data. Rincian hasil pelatihan dan pengujian dari berbagai model arsitektur pada algoritma jaringan saraf tiruan terdapat dalam Tabel 3-6 berikut, sedangkan untuk setiap model arsitektur menggunakan setingan *batch_size* 5 dan *epochs* 50.

Tabel 3 Hasil dari model arsitektur 5-30-1

No.	Nilai Aktual	Nilai Prediksi	APE
1	123	113.28	7.90
2	129	122.83	4.79
3	114	114.36	0.32
4	112	120.28	7.39
5	128	121.50	5.07

Tabel 4 Hasil dari model arsitektur 5-40-1

No.	Nilai Aktual	Nilai Prediksi	APE
1	123	112.90	8.21
2	129	120.01	6.97
3	114	110.02	3.49
4	112	113.23	1.10
5	128	117.80	7.97

Tabel 5 Hasil dari model arsitektur 5-50-1

No.	Nilai Aktual	Nilai Prediksi	APE
1	123	113.65	7.60
2	129	122.75	4.85
3	114	115.60	1.41
4	112	121.80	8.75
5	128	120.66	5.73

Tabel 6 Hasil dari model arsitektur 5-60-1

No.	Nilai Aktual	Nilai Prediksi	APE
1	123	112.52	8.52
2	129	121.01	6.19
3	114	114.83	0.73
4	112	119.09	6.33
5	128	119.38	6.74

Berdasarkan data hasil pelatihan dan pengujian pada Tabel 3-6 di atas, terlihat bahwa nilai APE pada setiap tabel berada di bawah 10. Meskipun nilai APE di bawah 10 adalah indikasi yang baik, sebaiknya juga mempertimbangkan faktor lain seperti kompleksitas model, waktu pelatihan, dan persyaratan bisnis sebelum memutuskan model mana yang akan digunakan dalam algoritma jaringan saraf tiruan.

E. Evaluasi

Berdasarkan hasil evaluasi dari keseluruhan model yang dibuat, model 5-40-1 ini menjadi model dengan performa yang relatif lebih baik. Model ini menggunakan 5 *neuron* pada lapisan *input*, 40 *neuron* pada lapisan *hidden* dan 1 *neuron* pada lapisan *output*.

Model 5-40-1 memiliki nilai performa (MAPE) yang paling rendah, yaitu sekitar 4.04, RMSE sebesar 6.71 dan nilai *performance* (akurasi) tertinggi sebesar 95.96%. Informasi ini dapat ditemukan pada Tabel 7 dan Gambar 3. Model ini dianggap sebagai model yang paling baik dalam memprediksi jumlah pakan ayam petelur berdasarkan evaluasi performa yang telah dilakukan.

Tabel 7 Perbandingan Model Arsitektur

No.	Model Arsitektur	MAPE	Akurasi (%)
1	5-30-1	4.52	95.48
2	5-40-1	4.04	95.96
3	5-50-1	5.07	94.93
4	5-60-1	4.54	95.46

Sumber: Data Olahan

IV. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah disampaikan, dapat

disimpulkan bahwa algoritma jaringan syaraf tiruan dengan model arsitektur 5-40-1 dapat digunakan atau dimanfaatkan untuk melakukan prediksi jumlah pakan ayam petelur. Hal ini dikarenakan model ini memiliki tingkat performa MAPE yang rendah sebesar 4.04, RMSE sebesar 6.71 dan tingkat akurasi yang tinggi sebesar 95.96%.

Nilai-nilai ini menunjukkan bahwa model tersebut cukup baik dalam memprediksi jumlah pakan yang diperlukan oleh ayam petelur, dan hasilnya lebih baik dibandingkan dengan tujuh model arsitektur lainnya yang telah dievaluasi. Secara keseluruhan, algoritma jaringan syaraf tiruan terbukti mampu menghasilkan tingkat keoptimalan yang baik, dengan nilai MAPE yakni 4.04, RMSE yakni 6.71 dan akurasi yang tinggi.

Dari hasil penelitian yang dilakukan, model dapat melakukan prediksi yang relatif cukup baik. Sebagai saran implementasi, model ini dapat digunakan pada industri peternakan, khususnya peternakan ayam petelur. Diharapkan model ini dapat melakukan prediksi yang baik pada jumlah pakan ayam petelur, sehingga para peternak dapat memangkas biaya pembelian pakan yang cukup besar.

DAFTAR PUSTAKA

- Adriono, E., Somantri, M., & Suryono, C. A. (2022). Model Prediksi Jumlah Pakan menggunakan Algoritma Evolusi Pikiran - Jaringan Syaraf Tiruan Rambat Balik untuk Budidaya Udang. *Jurnal Kelautan Tropis*, 25(2), 266–278. <https://doi.org/10.14710/jkt.v25i2.14256>
- ARTINI, W. (2017). Ragam Konsumsi Pangan Masyarakat Pedesaan Di Desa Margopatut Kecamatan Sawahan Kabupaten Nganjuk. *Jurnal Agrinika : Jurnal Agroteknologi Dan Agribisnis*, 1(1), 27–44. <https://doi.org/10.30737/agrinika.v1i1.304>
- Budiarto, A. A., Fatkhurrozi, B., & Setyowati, I. (2020). Implementasi Operator Canny Identifikasi Fertilitas Telur Ayam Buras. *Theta Omega: Journal of Electrical Engineering, Computer and Information Technology*, 1(2), 1–7.
- Frisca Siahaan, R. (2017). Mengawal Kesehatan Keluarga Melalui Pemilihan Dan Pengolahan Pangan Yang Tepat. *Jurnal Keluarga Sehat Sejahtera*, 15(2), 57–

64. <https://doi.org/10.24114/jkss.v15i2.8775>

- Gandhi Ramadhona, Budi Darma Setiawan, F. A. B. (2018). Prediksi Produktivitas Padi Menggunakan Jaringan Syaraf Tiruan Backpropagation. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(12), 6048–6057.
- Inggih Permana, F. N. S. (2022). The Effect of Data Normalization on the Performance of the Classification Results of the Backpropagation Algorithm. *IJIRSE: Indonesian Journal of Informatic Research and Software Engineering*, 2(1), 67–72.
- Joseph, V. R. (2022). Optimal ratio for data splitting. *Statistical Analysis and Data Mining*, 15(4), 531–538. <https://doi.org/10.1002/sam.11583>
- Kahlout, K. M., & Ekler, P. (2021). Algorithmic Splitting: A Method for Dataset Preparation. *IEEE Access*, 9, 125229–125237. <https://doi.org/10.1109/ACCESS.2021.3110745>
- Komariah, E., Octariadi, B. C., & Siregar, A. C. (n.d.). Penerapan Jaringan Syaraf Tiruan untuk Memprediksi Hasil Produksi Kelapa Sawit Menggunakan Backpropagation.
- Muhamad, I. M., Wardana, S. A., Wanto, A., & Windarto, A. P. (2022). Algoritma Machine Learning untuk penentuan Model Prediksi Produksi Telur Ayam Petelur di Sumatera. *Journal of Informatics ...*, 1(4), 126–134.
- Muraina, I. O. (2022). Ideal Dataset Splitting Ratios in Machine Learning Algorithms: General Concerns for Data Scientists and Data Analysts. *7th International Mardin Artuklu Scientific Researches Conference, February*, 496–504.
- Pamungkas, J., Winanjaya, R., Robiansyah, W., & Artikel, G. (2022). Metode Jaringan Saraf Tiruan dalam Memprediksi Jumlah Produksi Daging Itik Manila Berdasarkan Provinsi Di Indonesia Artificial Neural Network Method in Predicting the Amount of Manila Duck Meat Production by Province in Indonesia. *JOMLAI: Journal of Machine Learning and Artificial Intelligence*, 1(3), 2828–9099. <https://doi.org/10.55123/jomlai.v1i3.918>
- Sudarsono, A. (2016). 153217-ID-jaringan-syaraf-tiruan-untuk-memprediksi. *Jurnal Media Infotama*, 12(1), 61–69.

- Uzair, M., & Jamil, N. (2020). Effects of Hidden Layers on the Efficiency of Neural networks. *Proceedings - 2020 23rd IEEE International Multi-Topic Conference, INMIC 2020*, 1–6. <https://doi.org/10.1109/INMIC50486.2020.9318195>
- Whendasmoro, R. G., & Joseph, J. (2022). Analisis Penerapan Normalisasi Data Dengan Menggunakan Z-Score Pada Kinerja Algoritma K-NN. *JURIKOM (Jurnal Riset Komputer)*, 9(4), 872. <https://doi.org/10.30865/jurikom.v9i4.4526>
- Wibawa, M. S. (2017). Pengaruh Fungsi Aktivasi, Optimisasi dan Jumlah Epoch Terhadap Performa Jaringan Saraf Tiruan. *Jurnal Sistem Dan Informatika (JSI)*, 11(January 2017), 167–174. <https://doi.org/10.13140/RG.2.2.21139.94241>