

Penerapan Metode Jaringan Saraf Tiruan Dalam Memprediksi Produksi Daging Domba Menurut Provinsi

Listy Oktaviani, Sandy Erlangga, Bintang Aufa Sultan, Agus Perdana Windarto*, Putrama Alkhairi

Program Studi Sistem Informasi, STIKOM Tunas Bangsa, Pematang Siantar, Indonesia

Email: listyoktaviani1@gmail.com, sandyerlangga1998@gmail.com, bintangas21@gmail.com,

*agus.perdana@amiktunasbangsa.ac.id, putrama@amiktunasbangsa.ac.id

Email Penulis Korespondensi: agus.perdana@amiktunasbangsa.ac.id

Abstrak—Prediksi adalah proses untuk memperkirakan berapa kebutuhan dimasa yang akan datang. Penelitian ini bertujuan untuk memprediksi jumlah produksi daging domba berdasarkan provinsi. Daging domba merupakan salah satu sumber protein yang juga merupakan komoditas bernilai tinggi (high value commodities). Namun seiring meningkatnya produksi daging domba di Indonesia, tingkat konsumsi daging domba di Indonesia cenderung fluktuatif di beberapa tahun terakhir. Impor merupakan langkah yang paling sering dilakukan pemerintah dalam pemenuhan kebutuhan daging domba dalam negeri. Dengan menggunakan Jaringan Syaraf Tiruan dan algoritma backpropagation maka akan di prediksi jumlah produksi daging domba berdasarkan provinsi guna menentukan langkah pemenuhan kebutuhan daging domba dalam negeri yang didasarkan atas jumlah konsumsi daging domba masyarakat. Penelitian ini menggunakan data dari tahun 2001 sampai tahun 2022 dengan 1 target yaitu data tahun 2023.

Kata Kunci: Produksi Daging Domba; Prediksi; Backpropagation; Jaringan Syaraf Tiruan

Abstract—Prediction is the process of estimating future needs. This research aims to predict the amount of sheep meat production by province. Lamb is a source of protein which is also a high value commodity. However, along with the increase in lamb production in Indonesia, the level of lamb meat consumption in Indonesia has tended to fluctuate in recent years. Imports are the step most often taken by the government to meet domestic sheep meat needs. By using Artificial Neural Networks and the backpropagation algorithm, the amount of sheep meat production will be predicted based on provinces in order to determine steps to fulfill domestic sheep meat needs based on the amount of sheep meat consumption in the community. This research uses data from 2001 to 2022 with 1 target, namely data for 2023.

Keywords: Lamb Meat Production; Prediction; Backpropagation; Artificial Neural Network

1. PENDAHULUAN

Daging merupakan salah satu komoditas peternakan yang sangat penting untuk memenuhi kebutuhan protein masyarakat. Daging yang tersedia diharapkan tidak hanya terpenuhi dari segi kuantitasnya saja, akan tetapi juga harus diperhatikan dari segi kualitas [1], [2].

Domba merupakan hewan mamalia yang berukuran sedang. Domba banyak di pelihara oleh masyarakat Indonesia karena memiliki banyak keunggulan dan berpotensi meningkatkan ekonomi antara lain: tubuhnya relatif kecil, cepat mencapai dewasa kelamin, pemeliharaannya relatif mudah, tidak membutuhkan lahan yang luas, investasi modal usaha relatif kecil, mudah dipasarkan sehingga modal usaha cepat berputar. Selain itu ternak domba juga memiliki kelebihan lain yaitu: reproduksinya efisien dan dapat beranak 3 kali dalam 2 tahun [3], [4]. Domba juga memiliki daya adaptasi yang tinggi terhadap lingkungan, tahan terhadap panas dan beberapa penyakit serta prospek pemasaran yang baik. [5], [6] Tidak hanya di skala nasional tapi berdasarkan provinsi yang ada di Indonesia, bahkan Indonesia tidak mampu untuk mengekspor daging kambing secara kontinyu. Maka untuk menstabilkan persediaan produksi pemerintah harus mengetahui pangan dalam negeri. Melihat permasalahan ini maka diperlukan suatu metode yang dapat menghasilkan jumlah produksi daging domba berdasarkan provinsi di Indonesia, yang jauh lebih efektif agar memenuhi kebutuhan bahan pangan di seluruh provinsi di Indonesia [7], [8].

Metode backpropagation adalah salah satu metode yang dikembangkan untuk mendapatkan hasil perkiraan yang mendekati dengan data sebenarnya. Backpropagation membutuhkan data yang banyak, akan tetapi kondisi data yang ada sangat terbatas [9], [10].

Menurut Badan Pusat Statistik Indonesia, produksi daging domba mengalami skala produksi yang bervariasi bahkan Indonesia tidak bisa mengekspor daging domba secara terus menerus. Besarnya kebutuhan daging domba dapat ditentukan oleh konsumsi daging domba di Indonesia, konsumsi daging domba yang tinggi di Indonesia akan memaksa Indonesia mengimpor daging domba karena kekurangan stok [11], [12]. Harga daging domba naik dikarenakan kecenderungan impor daging domba. Berdasarkan penelitian sebelumnya di penelitian Sabda Zikurillah pada tahun 2022 mengenai prediksi jumlah produksi daging domba menghasilkan hasil prediksi dengan metode yang sama. Pada penelitian sebelumnya cara dalam pemrosesan pengerjaan melakukan pembagian data tidak dengan menggunakan pola rotasi melainkan dengan cara membagi kedua data tersebut, sementara pada penelitian saat ini dalam proses pengerjaan pembagian data testing dan training melakukan normalisasi dahulu kemudian membagi data training dan data testing menggunakan pola rotasi. Pada penelitian ini hal yang membedakan dengan penelitian sebelumnya adalah penggunaan arsitektur. Di penelitian sebelumnya menggunakan arsitektur 5 – 10 [13], [14]. Pada penelitian ini akurasi tertinggi diperoleh pada arsitektur 20-15-1 berbeda dengan penelitian sebelumnya yang menggunakan arsitektur 5-9-1 menghasilkan tingkat akurasi 94 %.

Pada penelitian terdahulu yang dilakukan oleh [15] dengan judul artikel “Analisis Metode Backpropagation Dalam Memprediksi Jumlah Produksi Daging Kambing di Indonesia“. Adapun arsitektur yang di gunakan pada artikel ini yaitu 20-25-1 dengan Mean Squared Error pengujian 0.00447765, pada arsitektur 20-30-1 menghasilkan Mean Squared Error 0.00300466, pada arsitektur 20-35-1 menghasilkan 0.00426823, pada arsitektur 20-37-1 menghasilkan 0.00357757. Berdasarkan arsitektur terbaik yang dihasilkan dalam penelitian ini yaitu arsitektur 20-15-1 dengan akurasi 90% dengan Mean Squared Error pengujian 0.00262384 pada epoch 27915 Iterations. Dengan demikian dapat disimpulkan bahwa algoritma backpropagation dapat memberikan akurasi yang baik dalam melakukan proses prediksi. Dengan adanya penelitian ini, industri peternakan dapat memanfaatkannya sebagai salah satu bahan untuk memprediksi daging kambing di masa mendatang.

Pada penelitian berikutnya yang dilaksanakan oleh [16] dengan pokok bahasana tentang “Identifikasi Kandungan Minyak Goreng Menggunakan Jaringan Saraf Tiruan Dengan Metode Backpropagation”, menghasilkan asitektur optimal yang diperoleh dari penelitian ini adalah 10 lapisan masukan, 18 lapisan tersembunyi pertama, 4 lapisan tersembunyi kedua, dan 1 lapisan keluaran. Semua lapisan ini menggunakan fungsi aktivasi sigmoid biner. Berdasarkan hasil pengujian, JST backpropagation mampu melakukan identifikasi dengan tingkat keberhasilan 100%.

Jika jumlah domba yang akan dihasilkan dapat diprediksi, maka industri peternakan Indonesia akan segera bereaksi dengan merumuskan kebijakan dan keputusan yang tepat untuk mengatasi masalah tersebut. Pemangku kepentingan di sektor peternakan memainkan peran penting dalam membantu ketersediaan daging. Memproduksi daging dalam jumlah yang tepat akan menstabilkan harga, tetapi jika jumlah daging yang diproduksi berkurang, konsumsi yang tidak mencukupi akan menyebabkan kekurangan daging sehingga harga akan meningkat[17]. Untuk menstabilkan harga daging domba dalam waktu dekat, industri peternakan perlu mengetahui berapa banyak daging yang dibutuhkan untuk diproduksi di masa depan [18] [19]. Untuk membuat prediksi diperlukan model dan data dasar untuk melakukan prediksi, sehingga pada saat finalisasi memberikan hasil yang akurat. Mempertimbangkan masalah ini, analisis dilakukan dengan menerapkan model prediksi yang cocok yang dapat digunakan sebagai alternatif dalam memprediksi produksi daging domba. Metode alternatif yang dapat digunakan untuk memprediksi produksi daging domba adalah jaringan saraf tiruan yang menggunakan metode algoritma backpropagation. Berdasarkan penelitian sebelumnya yaitu penelitian yang melakukan studi perbandingan Algoritma Backpropagation dan learning vector Quantization untuk pengenalan pola geometri, didapatkan kesimpulan bahwa Algoritma Back-propagation lebih baik dengan dibandingkan *learning vector quantization* [20]. Pada penelitian yang membandingkan dua metode jaringan saraf tiruan yaitu algoritma back-propagation dan metode *learning vector quantization* dalam melacak gangguan jantung coroner, disimpulkan bahwa algoritma back-propagation memiliki tingkat akurasi sebesar 68,76%.

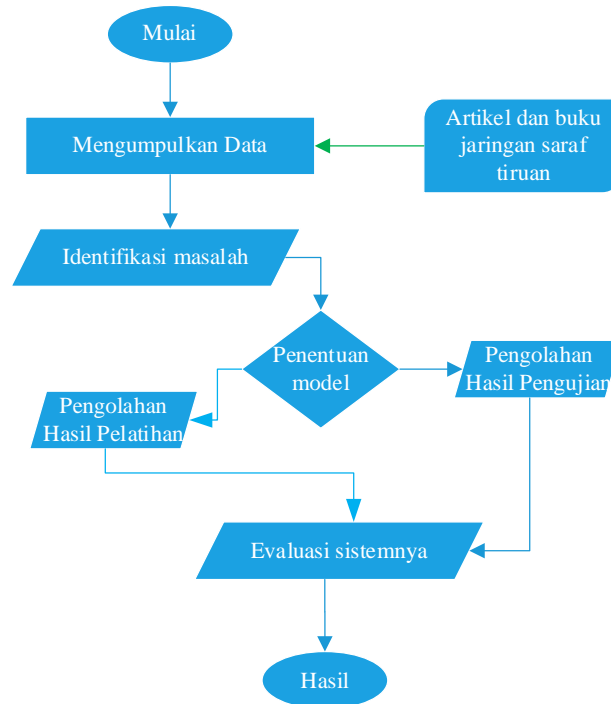
2. METODOLOGI PENELITIAN

Metode pengumpulan data yang digunakan dalam penelitian ini adalah jaringan syaraf tiruan dengan menggunakan metode algoritma back-propagation. Dataset yang digunakan dalam penelitian ini adalah dataset peternakan terkait produksi daging kambing per provinsi dari Badan Pusat Statistik (BPS) dengan link : <https://www.bps.go.id/indicator/24/483/1/produksi-daging-domba-menurut-provinsi.html> pada penelitian ini dataset yang digunakan adalah dataset dari tahun 2001 – 2022. Pada penelitian ini melakukan proses pengumpulan data dan data tersebut akan dinormalisasikan dengan menggunakan fungsi sigmoid lalu melakukan transformasi data. Selanjutnya akan dilakukan sebuah perancangan arsitektur jaringan dengan menggunakan aplikasi matlab R2011a, sehingga mendapatkan kesimpulannya.

2.1 Kerangka Kerja Penelitian

Pada gambar dibawah dapat dilihat bahwasannya pada proses peneletian ini tahap awal dilakukan sebuah pengumpulan data yang diperoleh dari Badan Pusat Statistik Indonesia yang diperoleh data dari tahun 2001-2022, pada penelitian ini juga melakukan proses pengumpulan referensi yang berasal dari berbagai jurnal di internet dan buku jaringan syaraf tiruan. Tahap selanjutnya setelah melakukan proses pengumpulan referensi dan pengumpulan data dilakukan proses identifikasi masalah penelitian dan melakukan normalisasi data dengan menggunakan fungsi sigmoid kemudian menentukan pembagian data latihan dan data uji. Selanjutnya melakukan proses penentuan pola ataupun arsitektur yang akan diuji pada aplikasi matlab. Setelah melakukan penentuan pola akan dilakukan sebuah proses pengujian data dan melakukan prediksi dan mengevaluasi hasil yang telah didapat.

Pada penelitian kali ini penulis menentukan karakteristik rancangan penelitian dengan beberapa tahap penyelesaian sebagai rangka dasar pengerjaan yang antara lain seperti terlihat pada gambar 1.



Gambar 1. Kerangka Kerja Penelitian

Langkah-langkah rancangan penelitian untuk proyek Anda tentang analisis metode backpropagation dalam memprediksi jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia [21]:

1. Mulai:

Penelitian ini akan dimulai dengan merumuskan pertanyaan penelitian yang jelas dan tujuan penelitian yang spesifik. Selain itu, perancangan kerangka kerja penelitian dan pemilihan teknik analisis yang akan digunakan juga akan dilakukan pada tahap awal ini.

2. Mengumpulkan Data dari Artikel dan Buku:

Pada tahap ini, data-data terkait jumlah perusahaan konstruksi di berbagai provinsi di Indonesia akan dikumpulkan dari artikel, buku, dan sumber-sumber tepercaya lainnya. Data-data ini akan menjadi dasar utama untuk analisis yang akan dilakukan.

3. Identifikasi Masalah:

Setelah data terkumpul, tahap identifikasi masalah akan melibatkan analisis terhadap data untuk mengidentifikasi pola dan tren yang mungkin menjadi masalah utama dalam distribusi perusahaan konstruksi di provinsi-provinsi Indonesia. Masalah-masalah ini kemudian akan difokuskan untuk dipecahkan melalui pendekatan backpropagation.

4. Penentuan Model:

Pada langkah ini, model jaringan saraf tiruan (neural network) dengan metode backpropagation akan dirancang. Penentuan struktur jaringan, jumlah lapisan, jumlah neuron dalam setiap lapisan, dan fungsi aktivasi yang akan digunakan akan diperhitungkan dengan cermat untuk memastikan model memiliki kapabilitas yang optimal dalam memprediksi jumlah perusahaan konstruksi.

5. Pelatihan:

Model yang telah dirancang akan dilatih menggunakan data yang telah dikumpulkan. Proses pelatihan ini akan melibatkan pengoptimalan parameter-model agar model dapat memahami pola-pola yang kompleks dalam data dan memprediksi jumlah perusahaan konstruksi dengan akurasi tinggi.

6. Pengujian:

Setelah model dilatih, langkah berikutnya adalah menguji performa model menggunakan data uji yang belum pernah dilihat oleh model sebelumnya. Pengujian ini bertujuan untuk menilai sejauh mana model dapat memprediksi jumlah perusahaan konstruksi dengan akurat di luar data pelatihan.

7. Evaluasi Hasil Pelatihan dan Penelitian:

Hasil pengujian akan dievaluasi secara kritis. Metrik-metrik seperti akurasi prediksi, nilai kesalahan, dan statistik lainnya akan dianalisis untuk menilai seberapa baik model ini dapat memprediksi jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia.

8. Selesai:

Pada tahap terakhir ini, hasil evaluasi akan disusun menjadi laporan akhir penelitian. Laporan ini akan mencakup temuan-temuan utama, analisis hasil, serta rekomendasi untuk pengembangan model dan penelitian lebih lanjut. Kesimpulan yang didapat dari penelitian ini akan dijabarkan dengan jelas, dan implikasi dari hasil penelitian ini terhadap industri konstruksi di Indonesia akan dibahas.

2.2 Jaringan Saraf Tiruan (JST)

Jaringan Syaraf Tiruan adalah suatu model yang kompleks dan non-linear, terdiri dari komponen-komponen yang memiliki perilaku serupa dengan model regresi. Jaringan syaraf tiruan dapat diilustrasikan dalam bentuk grafik, dan beberapa bagian dari grafik tersebut dapat memiliki perilaku yang serupa dengan gerbang logika [22]. Meskipun struktur jaringan saraf ditentukan terlebih dahulu, pengolahan yang terjadi dalam jaringan tidak menghasilkan hipotesis secara langsung [23], [24]. Sebaliknya, hipotesis dan pemrosesan lainnya terstruktur dalam jaringan ini berkembang selama proses pembelajaran. Hal ini memungkinkan neuron-neuron dalam jaringan untuk berperan sebagai pemecah masalah dalam "program" itu sendiri.

Proses pelatihan jaringan menggunakan algoritma backpropagation terdiri dari tiga langkah utama. Pertama, input pola pelatihan dikirimkan ke jaringan untuk melakukan feedforward. Kemudian, error yang terkait dengan output jaringan dikalkulasikan dan digunakan untuk melakukan backpropagation, yaitu menghitung error di setiap lapisan jaringan secara mundur. Langkah terakhir adalah penyesuaian bobot jaringan berdasarkan error yang dihasilkan, sehingga bobot jaringan dapat diperbarui untuk memperbaiki performa jaringan [25].

Pada algoritma *backpropagation* dalam penyelesaian masalah terdapat beberapa langkah-langkah yang digunakan sebagai berikut [21].

Tahap 0 : Memberikan nilai pertama pada bobot yang dilakukan secara acak dan memperhatikan *learning rate*.

Tahap 1 : Ketika error yang ditemukan belum mencapai batas yang ditentukan maka lanjut langkah berikut.

Tahap *feedforward*

a. *Neuron input* x_i dengan $i = 1, 2, 3, \dots, n$ mendapatkan x_i lalu diteruskan ke setiap *neuron* lapisan tersembunyi.

b. *Neuron* lapisan tersembunyi Z_j dengan $j = 1, 2, 3, \dots, p$ menjumlahkan input yang berbobot

$$Z_{in_j} = V_{0j} + \sum_i^n 1X_iV_{ij} \quad (1)$$

Hitunglah sinyal *output* lapisan tersembunyi ketika memakai fungsi aktivasi:

$$Z_j = \frac{1}{1+e^{-z_{in_j}}} \quad (2)$$

c. *Neuron output* y_k dengan $k=1, 2, 3, \dots, m$ menjumlahkan input berbobot:

$$y_{in_k} = V_{0k} + \sum_j^p 1Z_jW_{jk} \quad (3)$$

Memakai fungsi aktivasi lalu hitung sinyal hasil pada lapisan hasil dengan persamaan :

$$y_k = \frac{1}{1+e^{-y_{in_k}}} \quad (4)$$

Tahap Algoritma *backpropagation*, meliputi:

a. Pada setiap neuron hasil y_k dengan $k = 1, 2, 3, \dots, m$, menerima target pola hasil yang berhubungan dengan pola input dan pelatihan.

b. Pada neuron lapisan tersembunyi Z_j dengan $j = 1, 2, 3, \dots, p$ menjumlahkan factor delta di lapisan tersembunyi

Pada neuron hasil y_k dengan $k=1, 2, 3, \dots, m$, mengupgrade bobot *hidden layer* menuju *output layer*

3. HASIL DAN PEMBAHASAN

3.1 Penetapan Input

Penetapan input pada penelitian ini diambil dari jumlah tahun yang terdapat pada data yang terdapat pada Badan Pusat Statistik Indonesia. Data produksi daging Domba pada penelitian ini menggunakan data pada tahun 2000-2022. Data tersebut yang akan menjadi panduan dalam pengambilan keputusan dalam pengambilan keputusan ketika melakukan suatu prediksi dengan menggunakan algoritma backpropagation. Pada penelitian ini memiliki beberapa jumlah input yang mana dapat dilihat pada tabel 1. Tabel 1 menjelaskan bahwasannya input yang terdapat pada penelitian ini memiliki 23 variabel dengan variable X1 sampai variable X23. Pada setiap variable memiliki kriterianya masing-masing

Tabel 1. Daftar Input Data Produksi Daging Domba

No	Variabel	Nama Kriteria
1	X1	2000
2	X2	2001
3	X3	2002
4	X4	2003
5	X5	2004
6	X6	2005
7	X7	2006
8	X8	2007
9	X9	2008

No	Variabel	Nama Kriteria
10	X10	2009
11	X11	2010
12	X12	2011
13	X13	2012
14	X14	2013
15	X15	2014
16	X16	2015
17	X17	2016
18	X18	2017
19	X19	2018
20	X20	2019
21	X21	2020
22	X22	2021
23	X23	2022

3.2 Penetapan Output

Dalam penelitian ini, langkah yang paling diantisipasi adalah langkah yang akan menghasilkan perkiraan terbaik jumlah daging domba pada tahun 2023. Untuk mencapai hasil prediksi jumlah tertinggi, arsitektur terbaik harus digunakan dengan jumlah paling sedikit. kesalahan mungkin. Ambang batas kesalahan yang digunakan dalam penelitian ini minimal 0,05 dengan ambang batas benar(1) dan salah(0). Semakin sedikit kesalahan yang dapat dibuat akan menghasilkan analisis yang lebih menguntungkan.

3.3 Pengolahan Data Latih

Untuk penelitian ini digunakan data produksi daging domba di Indonesia dari tahun 2000 hingga 2022. Data yang diperoleh dari Badan Pusat Statistik sebelum pelaksanaan Matlab lebih teliti dinormalisasi dengan fungsi sigmoid Excel (tidak melebihi 0 atau 1). Pada penelitian ini, data yang telah dinormalisasi dengan menggunakan fungsi sigmoid akan dibagi menjadi dua kategori, yaitu data latih dan uji. Dalam artikel ini, periode waktu yang dicakup oleh data adalah 2000–2022 untuk data latih dan 2001–2022 untuk data uji. Sebelum pengolahan data latih dan uji, data dinormalisasi lebih menyeluruh. Oleh karena itu, normalisasi data dapat disajikan dengan menggunakan perbandingan berikut.

$$X^1 = \frac{0.8(x-min)}{max-min} + 0.1$$

Keterangan :

X^1 = Normalisasi Data min = Data terendah dari semua data 0.8 = Interval

X = Data yang dinormalisasi max = Data tertinggi dari semua data 0.1 = Interval

Tabel 2 menunjukkan data latih yang telah dinormalisasi dengan menggunakan fungsi sigmoid. Data latih atau biasa disebut dengan data *training* ini adalah data yang akan digunakan pada aplikasi matlab sebelum melakukan proses pengujian.

Tabel 2. Data Training Setelah Dinormalisasi

Provinsi	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009
Aceh	0,1056	0,1056	0,1059	0,1059	0,1061	0,1030	0,1121	0,1183	0,1016	0,1025
Sumatera Utara	0,1090	0,1097	0,1105	0,1114	0,1111	0,1114	0,1166	0,1232	0,1204	0,1227
Sumatera Barat	0,1012	0,1001	0,1002	0,1002	0,1002	0,1002	0,1007	0,1002	0,1004	0,1003
Jambi	0,1013	0,1011	0,1007	0,1009	0,1009	0,1010	0,1015	0,1013	0,1060	0,1029
Sumatera Selatan	0,1056	0,1006	0,1013	0,1012	0,1014	0,1014	0,1141	0,1040	0,1002	0,1001
Bengkulu	0,1005	0,1009	0,1010	0,1001	0,1001	0,1001	0,1001	0,1003	0,1036	0,1036
Lampung	0,1008	0,1012	0,1010	0,1017	0,1020	0,1020	0,1041	0,1028	0,1000	0,1000
DKI Jakarta	0,1011	0,1081	0,1059	0,1089	0,1034	0,1059	0,1086	0,1080	0,4741	0,6321
Jawa Barat	0,1049	0,4987	0,8389	0,9000	0,8129	0,5237	0,8320	0,6347	0,1937	0,2102
Jawa Tengah	0,3651	0,1775	0,2017	0,2241	0,1925	0,1864	0,1952	0,1647	0,1229	0,1307
DI Yogyakarta	0,1831	0,1249	0,1235	0,1165	0,1213	0,1277	0,1816	0,1224	0,2446	0,1710
Jawa Timur	0,1228	0,2090	0,2105	0,2334	0,2357	0,2377	0,2398	0,2426	0,1397	0,1462
Bali	0,2159	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1005	0,1027
Nusa Tenggara Barat	0,2159	0,1004	0,1007	0,1009	0,1013	0,1007	0,1002	0,1012	0,1057	0,1048
Kalimantan Barat	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1025	0,1001
Kalimantan Tengah	0,1002	0,1001	0,1001	0,1005	0,1002	0,1002	0,1000	0,1024	0,1004	0,1004
Kalimantan Selatan	0,1000	0,1003	0,1002	0,1004	0,1004	0,1002	0,1009	0,1004	0,1001	0,1001
Sulawesi Tengah	0,1001	0,1009	0,1010	0,1022	0,1013	0,1004	0,1002	0,1002	0,1000	0,1000
Sulawesi Selatan	0,1002	0,1001	0,1002	0,1001	0,1001	0,1000	0,1002	0,1000	0,1000	0,1000

Tabel 3. Lanjutan Data training setelah dinormalisasi

Provinsi	2010	2011	2012	2013	2014	2015	2016	2020	2021
Aceh	0,1028	0,1048	0,1052	0,1055	0,1068	0,1076	0,1123	0,1054	0,1069
Sumatera Utara	0,1242	0,1246	0,1264	0,1286	0,1292	0,1292	0,1372	0,1077	0,1087
Sumatera Barat	0,1005	0,1002	0,1000	0,1001	0,1001	0,1001	0,1001	0,1005	0,1003
Jambi	0,1040	0,1031	0,1024	0,1052	0,1030	0,1029	0,1030	0,1022	0,1038
Sumatera Selatan	0,1002	0,1002	0,1003	0,1002	0,1007	0,1009	0,1002	0,1001	0,1000
Bengkulu	0,1008	0,1009	0,1008	0,1012	0,1008	0,1009	0,1007	0,1017	0,1022
Lampung	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1002
DKI Jakarta	0,5211	0,5088	0,5070	0,4379	0,4671	0,4502	0,4597	0,6149	0,5924
Jawa Barat	0,1836	0,2070	0,1825	0,1828	0,1932	0,1912	0,1940	0,2049	0,1959
Jawa Tengah	0,1228	0,1339	0,1108	0,1338	0,1356	0,1356	0,1392	0,1447	0,1383
DI Yogyakarta	0,1717	0,1779	0,1809	0,1825	0,1894	0,1881	0,2126	0,2013	0,1933
Jawa Timur	0,1416	0,1457	0,1547	0,1470	0,1361	0,1711	0,1387	0,1473	0,1358
Bali	0,1036	0,1044	0,1036	0,1003	0,1000	0,1000	0,1000	0,1000	0,1000
Nusa Tenggara Barat	0,1039	0,1013	0,1012	0,1058	0,1059	0,1048	0,1048	0,1021	0,1011
Kalimantan Barat	0,1001	0,1001	0,1000	0,1001	0,1002	0,1001	0,1001	0,1000	0,1001
Kalimantan Tengah	0,1005	0,1002	0,1002	0,1003	0,1001	0,1001	0,1002	0,1001	0,1001
Kalimantan Selatan	0,1001	0,1000	0,1000	0,1001	0,1000	0,1000	0,1000	0,1001	0,1001
Sulawesi Tengah	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000
Sulawesi Selatan	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000	0,1000

Dapat dilihat dari tabel 2 dan tabel 3 bahwasannya menjelaskan tabel lanjutan data training setelah dinormalisasi yang dimulai pada tahun 2012-2021. Data tersebut merupakan data yang digunakan sebagai data pengujian yang akan diimplementasikan aplikasi matlab.

3.4 Perancangan Arsitektur Dan Hasil

Setelah melakukan analisis data menggunakan fungsi sigmoid, sekarang akan dilakukan proses perencanaan arsitektur dengan menggunakan software Matlab. Pada contoh ini, perancangan arsitektural design menggunakan matlab R2011a. Penulis menggunakan beberapa arsitektur jaringan yang berbeda dalam esai ini. Dari hasil percobaan tersebut, dimungkinkan untuk mendapatkan desain arsitektur yang unggul dengan tingkat akurasi yang tinggi. Desain ini adalah 20-15-1 dengan MSE pelatihan 0.00100037 dan MSE eksperimen 0.00262384 dan memiliki 27915 iterasi. Hasil dari arsitektur 20-15-1 dapat ditunjukkan pada tabel di bawah ini. Seperti dapat dilihat pada tabel 4, implementasi perangkat lunak MathLab menghasilkan keluaran dan kesalahan. SSE dihasilkan sebagai akibat dari kesalahan ini, dan dua hari kemudian, jumlah SSE ditentukan oleh jumlah SSE yang dibandingkan dengan jumlah SSE.

Tabel 4. Hasil data training pengujian arsitektur terbaik

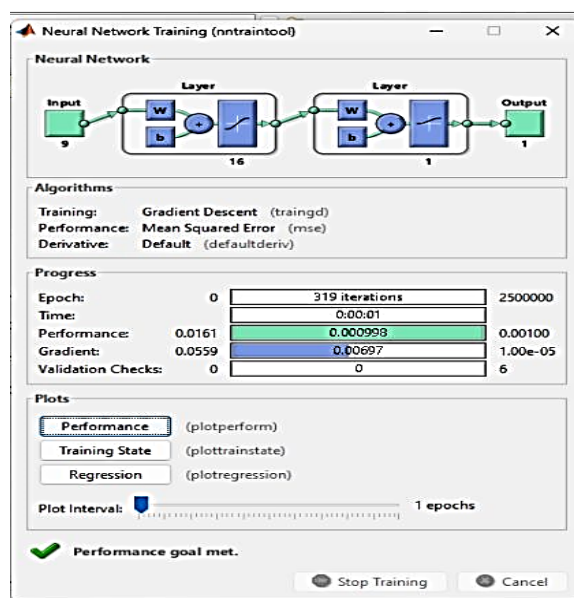
Provinsi	Output	Error	See	Akurasi
Aceh	0.0950	0.0075	0,00005625	1
Sumatera Utara	0.1021	0.0207	0,00042849	1
Sumatera Barat	0.0937	0.0066	0,00004356	1
Jambi	0.0964	0.0065	0,00004225	1
Sumatera Selatan	0.0939	0.0062	0,00003844	1
Bengkulu	0.0954	0.0082	0,00006724	1
Lampung	0.0934	0.0066	0,00004356	1
DKI Jakarta	0.6048	0.0274	0,00075076	1
Jawa Barat	0.1826	0.0276	0,00076176	1
Jawa Tengah	0.2485	-0.1179	0,01390041	0
DI Yogyakarta	0.2031	-0.0321	0,00103041	1
Jawa Timur	0.1107	0.0355	0,00126025	1
Bali	0.0885	0.0142	0,00020165	1
Nusa Tenggara Barat	0.0914	0.0134	0,00017956	1
Kalimantan Barat	0.0951	0.0049	0,00002401	1
Kalimantan Tengah	0.0941	0.0063	0,00003969	1
Kalimantan Selatan	0.0939	0.0062	0,00003844	1
Sulawesi Tengah	0.0936	0.0064	0,00004096	1
Sulawesi Selatan	0.0937	0.0063	0,00003969	1
			Jlh SSE	0,01898737
			MSE	0,000999335

Dapat dilihat dari tabel 5 menunjukkan bahwa arsitektur 20-15-1 dapat menghasilkan keakuratan sebesar 90% dengan menghitung jumlah data yang benar berdasarkan learning rate yang telah ditentukan dan membagi dengan jumlah data lalu dikalikan dengan 100 sehingga mendapatkan persentase keakuratannya.

Tabel 5. Hasil data testing pengujian arsitektur terbaik

Provinsi	Output	Error	See	Akurasi	
Aceh	0.0953	0.0117	0,00013689	1	
Sumatera Utara	0.0876	0.0215	0,00046225	1	
Sumatera Barat	0.0938	0.0065	0,00004225	1	
Jambi	0.0937	0.0097	0,00009409	1	
Sumatera Selatan	0.0935	0.0066	0,00004356	1	
Bengkulu	0.0945	0.0079	0,00006241	1	
Lampung	0.0939	0.0063	0,00003969	1	
DKI Jakarta	0.5370	0.1079	0,01164241	0	
Jawa Barat	0.1549	0.0411	0,00168921	1	
Jawa Tengah	0.1013	0.0372	0,00138384	1	
DI Yogyakarta	0.1556	0.0401	0,00160801	1	
Jawa Timur	0.0889	0.0521	0,00271441	0	
Bali	0.0919	0.0082	0,00006724	1	
Nusa Tenggara Barat	0.0926	0.0086	0,00007396	1	
Kalimantan Barat	0.0938	0.0062	0,00003844	1	
Kalimantan Tengah	0.0936	0.0065	0,00004225	1	
Kalimantan Selatan	0.0938	0.0063	0,00003969	1	
Sulawesi Tengah	0.0938	0.0062	0,00003844	1	
Sulawesi Selatan	0.0938	0.0062	0,00003844	1	
			Jlh SSE	0,02025748	90%
			MSE	0,00106618	

Dari gambar 2 dijelaskan bahwa model arsitektur 9-16-1 telah memperoleh Epoch dengan 319 iterations dalam waktu 00.01 detik dan memperoleh performance goal dengan nilai 0.00099935. Pada artikel ini untuk pengaplikasian pada aplikasi matlab dalam perancangan arsitektur jaringan menggunakan *Train Gradient Descent* “traingd”.



Gambar 2. Hasil Data *Training* 9-16-1-1

Pada gambar 2 dapat dilihat bahwa diperoleh hasil *epoch* yang terjadi sebanyak 319 *iterations* dengan waktu 00:00:01 detik.

3.5 Pembahasan

Pada penelitian ini dalam mengambil hasil terbaik penulis menggunakan 5 arsitektur yang telah di uji menggunakan aplikasi mathlan R2011a. Pada saat menerapkan model arsitektur memiliki hasil yang berbeda-beda dan dapat dilihat pada tabel sebelumnya bahwasannya arsitektur terbaik didapat pada model 9-16-1. Tabel 6 menunjukkan arsitektur yang

telah diuji. Dapat dilihat pada tabel 6 bahwasannya akurasi pelatihan dapat lebih baik dibandingkan dengan akurasi pengujian.

Tabel 6. Rekapitulasi Hasil Arsitektur

Arsitektur	Epoch	Time (Detik)	Mse Pelatihan	Akurasi	Mse Pengujian	Akurasi
9-16-1	319	00:01	0.000.999.335	95%	0.001.066.183	90%
9-17-1	601	01:22	0.001.000.005	95%	0.022.379.533	80%
9-18-1	1043	00:03	0.000.998.499	95%	0.022.334.644	84%
9-19-1	8557	00:19	0.000.999.994	95%	0.003.005.871	84%
9-20-1	652	00:01	0.000.997.917	90%	0.001.716.342	90%

Penelitian ini melibatkan pengujian beberapa arsitektur model jaringan saraf tiruan (9-16-1, 9-17-1, 9-18-1, 9-19-1, 9-20-1) untuk memprediksi jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia. Berikut adalah analisis hasil penelitian berdasarkan data yang disediakan:

3.5.1 Arsitektur Model:

Dalam penelitian ini, berbagai arsitektur model jaringan saraf tiruan telah diuji. Sebagian besar arsitektur memiliki satu lapisan input dengan jumlah neuron sebanyak 9. Namun, jumlah neuron pada lapisan tersembunyi bervariasi (dari 16 hingga 20) untuk setiap arsitektur. Jumlah neuron ini menentukan kompleksitas dan kapasitas model dalam memahami pola data.

3.5.2 Epoch dan Waktu Pelatihan:

Jumlah epoch mengindikasikan seberapa sering model melihat keseluruhan dataset selama pelatihan. Peningkatan jumlah epoch tidak selalu menghasilkan peningkatan performa model. Meskipun arsitektur 9-19-1 memerlukan waktu pelatihan yang cukup lama (8557 detik atau sekitar 2.38 jam), peningkatan waktu tersebut tidak selalu menghasilkan peningkatan akurasi yang signifikan, menunjukkan adanya hukum rendah utilitas pada peningkatan waktu pelatihan.

3.5.3 Mean Squared Error (MSE):

MSE pelatihan dan pengujian mencerminkan seberapa baik model memahami data latih dan seberapa baik ia memprediksi data uji. Nilai MSE yang rendah menunjukkan bahwa model memiliki kemampuan yang baik dalam memprediksi data. Dalam penelitian ini, sebagian besar arsitektur memiliki nilai MSE yang cukup rendah pada data pelatihan, menunjukkan bahwa model dapat memahami pola data dengan baik. Namun, pada data pengujian, beberapa arsitektur mengalami peningkatan MSE, menandakan adanya overfitting, terutama pada arsitektur 9-17-1 dan 9-18-1.

3.5.4 Akurasi

Akurasi mencerminkan sejauh mana model berhasil memprediksi jumlah perusahaan konstruksi dengan benar. Tingkat akurasi yang tinggi, terutama pada arsitektur 9-16-1 (95%), menunjukkan bahwa model dapat memprediksi dengan tingkat keberhasilan yang signifikan.

4. KESIMPULAN

Berdasarkan hasil penelitian ini, arsitektur model 9-16-1 menonjol sebagai konfigurasi terbaik untuk memprediksi jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia. Model ini mencapai tingkat akurasi yang sangat baik (95%) dengan waktu pelatihan yang cukup efisien (319 detik atau sekitar 5 menit). Di sisi lain, beberapa arsitektur lainnya, khususnya 9-17-1 dan 9-18-1, mengalami overfitting pada data pengujian, yang mengurangi kehandalannya dalam menggeneralisasi data yang belum pernah dilihat sebelumnya.

REFERENCES

- [1] S. Rahayu, E. L. Aditia, and S. Jamil, "Sifat Fisik Daging Domba Garut Jantan dengan Waktu Pemberian Pakan yang Berbeda Physical Meat Characteristics of Garut Lamb with Different Feeding Time," *J. Ilmu Produksi dan Teknol. Has. Peternak.*, vol. 03, no. 2, pp. 79–82, 2015.
- [2] S. R. A. 1Jurusan Fadhila FIRDAUSA1*, Raja MARPAUNG2, "SIMULASI METODE BACK PROPAGATION DALAM ANALISIS HASIL PENGARUH BIJI KARET SUBSTITUSI AGREGAT KASAR TERHADAP KUAT TEKAN BETON," vol. 8, no. 2, 2020.
- [3] X. D. Crystallography, "BACKPROPAGATION NEURAL NETWORK DALAM MEMREDIKSI FINANCIAL DISTRESS PADA PERUSAHAAN BADAN USAHA MILIK NEGARA (BUMN) SEKTOR TRANSPORTASI DAN PERGUDANGAN," pp. 1–23, 2016.
- [4] P. Alkhairi and A. P. Windarto, "Analisis Dalam Menentukan Produk BRI Syariah Terbaik Berdasarkan Dana Pihak Ketiga Menggunakan AHP," *CESS (Journal Comput. Eng. Syst. Sci.)*, vol. 3, no. 1, pp. 60–64, 2018.

- [5] A. Revi, S. Solikhun, and M. Safii, "Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Produksi Daging Sapi Berdasarkan Provinsi," *KOMIK (Konferensi Nas. Teknol. Inf. dan Komputer)*, vol. 2, no. 1, pp. 297–304, 2018, doi: 10.30865/komik.v2i1.941.
- [6] P. Alkhairi and A. P. Windarto, "Penerapan K-Means Cluster pada Daerah Potensi Pertanian Karet Produktif di Sumatera Utara," *Semin. Nas. Teknol. Komput. Sains*, pp. 762–767, 2019.
- [7] S. Zikrullah, H. S. Tambunan, and Susiani, "Memprediksi Jumlah Produksi Daging Kambing Berdasarkan Provinsi Di Indonesia Dengan Menggunakan Jaringan Saraf Tiruan Backpropagation," *ZAHRA Bull. Big Data, Data Sci. Artif. Intell.*, vol. 1, no. 2, pp. 97–105, 2022.
- [8] P. Alkhairi and B. H. Hayadi, "Pemodelan Artificial Neural Network Peramalan Tingkat Kenaikan Jabatan Berdasarkan Kinerja Pegawai Menggunakan ...," *Smart EDU Bul. Educ.*, vol. 1, no. 2, pp. 73–84, 2022, [Online]. Available: <https://ejournal.abivasi.id/index.php/SmartEDU/article/view/21>
- [9] Sugiyono, "Dokumen Karya Ilmiah | Skripsi | Prodi Teknik Informatika - S1 | FIK | UDINUS | 2016," *Fik*, vol. 1, no. 1, pp. 1–2, 2016.
- [10] B. H. H. Putrama Alkhairi, "Penerapan algoritma backpropagation untuk mengenali pola tulisan angka dengan fungsi pelatihan gradient descent with momentum adaptive lr 1,2," vol. 1, no. 3, pp. 126–139, 2022.
- [11] R. Yusuf *et al.*, "Application of Analytical Hierarchy Process Method for SQM on Customer Satisfaction," *J. Phys. Conf. Ser.*, vol. 1783, no. 1, 2021, doi: 10.1088/1742-6596/1783/1/012019.
- [12] P. Alkhairi, E. R. Batubara, R. Rosnelly, W. Wanayaumini, and H. S. Tambunan, "Effect of Gradient Descent With Momentum Backpropagation Training Function in Detecting Alphabet Letters," *Sinkron*, vol. 8, no. 1, pp. 574–583, 2023, doi: 10.33395/sinkron.v8i1.12183.
- [13] Putrama Alkhairi and A. P. Windarto, "Classification Analysis of Back propagation-Optimized CNN Performance in Image Processing," *J. Syst. Eng. Inf. Technol.*, vol. 2, no. 1, pp. 8–15, 2023, doi: 10.29207/joseit.v2i1.5015.
- [14] P. Alkhairi, L. P. Purba, A. Eryzha, A. P. Windarto, and A. Wanto, "The Analysis of the ELECTREE II Algorithm in Determining the Doubts of the Community Doing Business Online," *J. Phys. Conf. Ser.*, vol. 1255, no. 1, 2019, doi: 10.1088/1742-6596/1255/1/012010.
- [15] R. Setiana, R. A. Siregar, F. Husaini, and A. P. Windarto, "Analisis Metode Backpropagation Dalam Memprediksi Jumlah Produksi Daging Kambing di Indonesia Produksi Daging Kambing (TON)," vol. 2, no. 3, pp. 97–109, 2023.
- [16] N. ULYA, "IDENTIFIKASI KANDUNGAN MINYAK GORENG MENGGUNAKAN JARINGAN SARAF TIRUAN DENGAN METODE BACKPROPAGATION," 2019.
- [17] M. M. Dewi, L. D. Farida, M. Nuraminudin, M. Informatika, U. Amikom, and K. Kunci, "REGRESI LINIER UNTUK PREDIKSI KONSUMSI DAN PRODUKSI DAGING UNGGAS," vol. 4, no. 2, 2023.
- [18] Z. Ottay, Rifaldy.Satria, Heru.Almaida, "IMPLEMENTASI METODE BACK-PROPAGATION DALAM MEMPREDIKSI JUMLAH PRODUKSI DAGING AYAM RAS PEDAGING DI INDONESIA.," vol. 2, no. 2, pp. 66–74, 2022.
- [19] D. Hartama, A. Perdana Windarto, and A. Wanto, "The Application of Data Mining in Determining Patterns of Interest of High School Graduates," *J. Phys. Conf. Ser.*, vol. 1339, no. 1, 2019, doi: 10.1088/1742-6596/1339/1/012042.
- [20] Y. Hendriyani, "Perbandingan Algoritma Backpropagation dan Learning Vector Quantization (LVQ) dalam Pengenalan Pola Bangun Datar Geometri," vol. 20, no. 2, pp. 59–66, 2020.
- [21] A. Rahmat, H. Hardi, F. A. Syam, Z. Zamzami, B. Febriadi, and A. P. Windarto, "Utilization of the field of data mining in mapping the area of the Human Development Index (HDI) in Indonesia," *J. Phys. Conf. Ser.*, vol. 1783, no. 1, 2021, doi: 10.1088/1742-6596/1783/1/012035.
- [22] A. G. Salman and Y. L. Prasetyo, "DENGAN METODE PEMBELAJARAN G RADIANT DESCENT ADAPTIVE LEARNING RATE UNTUK PENDUGAAN CURAH HUJAN BERDASARKAN PEUBAH ENSO Afan Galih Salman ; Yen Lina Prasetyo," vol. 1, no. 2, pp. 418–429.
- [23] K. Fatmawati *et al.*, "Analysis of Promothee II Method in the Selection of the Best Formula for Infants under Three Years," *J. Phys. Conf. Ser.*, vol. 1255, no. 1, 2019, doi: 10.1088/1742-6596/1255/1/012009.
- [24] Z. Xu, A. M. Dai, J. Kemp, and L. Metz, "Learning an Adaptive Learning Rate Schedule," *arXiv*, vol. 1909.09712, 2019.
- [25] N. A. Hamid and N. M. Nawati, "Accelerating Learning Performance of Back Propagation Algorithm by Using Adaptive Gain Together with Adaptive Momentum and Adaptive Learning Rate on Classification Problems," pp. 559–560.
- [26] M. Thoriq, "Peramalan Jumlah Permintaan Produksi Menggunakan Jaringan Saraf Tiruan Algoritma Backpropagation," *J. Inf. dan Teknol.*, vol. 4, pp. 27–32, 2022, doi: 10.37034/jidt.v4i1.178.