

Analisis Metode *Backpropagation* Dalam Memprediksi Jumlah Produksi Daging Kambing di Indonesia

Rika Setiana*, Razalfa Aindi Siregar, Fahry Husaini, Agus Perdana Windarto

Sistem Informasi, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: ^{1,*}rikasetiana957@gmail.com, ²razalfaaindi@email.com, ³fahry.husaini1212@gmail.com,

⁴agus.perdana@amiktunasbangsa.ac.id

Email Korespondensi: rikasetiana957@gmail.com

Abstrak—Suatu pengetahuan yang selalu berkembang pesat sampai saat ini adalah jaringan saraf tiruan. Suatu ilmu komputasi yang bekerja seperti system saraf manusia merupakan jaringan saraf tiruan. Jaringan saraf tiruan dengan metode *backpropagation* dapat membuat sebuah prediksi pada sebuah data. Pada artikel ini akan dilakukan sebuah prediksi terhadap jumlah produksi kambing di Indonesia. Kambing merupakan salah satu hewan ternak yang dapat menghasilkan daging yang bergizi. Kurangnya daging kambing akan menyebabkan naiknya harga daging kambing. Dengan memproduksi daging kambing yang memadai membantu menstabilkan harga daging, tetapi jika produksi daging kambing kurang dari permintaan, maka akan menyebabkan kenaikan harga. Oleh karena itu, melihat permasalahan di atas penelitian ini bertujuan untuk memprediksi daging kambing agar kedepannya dapat mengetahui seberapa banyak daging kambing yang harus diprediksi dengan cara melakukan proses pengolahan data terlebih dahulu lalu dijadikan input dalam memprediksi jumlah produksi daging kambing. Prediksi merupakan salah satu cara untuk memperkirakan permintaan masa depan. Menghindari kurangnya ketersediaan daging, dengan cara memprediksi jumlah daging kambing yang diproduksi sedemikian rupa agar tidak terjadi kelangkaan daging kambing dan fluktuasi harga daging kambing di pasar. Metode dan data dasar diperlukan untuk membuat prediksi. Dalam penelitian ini data diperoleh dari BPS Indonesia bagian peternakan yang menggunakan data tahun 2001-2021 sebagai data latih dan 2002-2022 sebagai data uji. Metode yang diaplikasikan pada artikel ini adalah algoritma *backpropagation*. Pada artikel ini mengaplikasikan 5 arsitektur jaringan yang diimplementasikan pada aplikasi matlab. 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.

Kata Kunci: Jaringan Saraf Tiruan; *Backpropagation*; Prediksi; Produksi; Indonesia

Abstract—A science that has always developed rapidly until now is artificial neural networks. A computational science that works like the human nervous system is an artificial neural network. Artificial neural networks with the *backpropagation* method can make a prediction on data. In this article, a prediction will be made on the amount of goat production in Indonesia. Goats are one of the livestock that can produce nutritious meat. The lack of goat meat will cause the price of goat meat to rise. Producing enough goat meat helps stabilize the price of meat, but if goat meat production is less than demand, it will lead to price increases. Therefore, looking at the problems above, this study aims to predict goat meat so that in the future it can know how much goat meat must be predicted by processing data first and then being used as input in predicting the amount of goat meat production. Prediction is one way to estimate future demand. Avoiding the lack of meat availability, by predicting the amount of goat meat produced in such a way that there is no scarcity of goat meat and fluctuations in the price of goat meat in the market. Basic methods and data are required to make predictions. In this study, data was obtained from BPS Indonesia in the livestock section using data from 2001-2021 as training data and 2002-2022 as test data. The method applied in this article is the *backpropagation* algorithm. This article applies 5 network architectures implemented in the matlab application. The architecture used in this article is 20-25-1 with a *Mean Squared Error* testing 0.00447765, in 20-30-1 architecture produces *Mean Squared Error* 0.00300466, in 20-35-1 architecture produces 0.00426823, in 20-37-1 architecture produces 0.00357757. Based on the best architecture produced in this study, the 20-15-1 architecture with 90% accuracy with a *Mean Squared Error* testing 0.00262384 at epoch 27915 Iterations. Thus it can be concluded that the *backpropagation* algorithm can provide good accuracy in the prediction process. With this research, the livestock industry can utilize it as one of the materials to predict goat meat in the future.

Keywords: Artificial Neural Network; *Backpropagation*; Prediction; Production; Indonesia

1. PENDAHULUAN

Jumlah penduduk Indonesia yang terus bertambah berarti permintaan akan berbagai jenis makanan terus bertambah. Konsumsi produk hewani seperti daging dan produk lainnya secara umum sangat tinggi di Indonesia [1]. Indonesia adalah negara yang sangat padat penduduknya dan memiliki banyak masalah yang berbeda. Salah satunya adalah ketersediaan pangan. Pada saat ini daging kambing merupakan salah satu bahan pangan yang konsumsinya semakin meningkat seiring bertambahnya jumlah penduduk[2]. Produk hewani yang paling erat kaitannya dengan kehidupan manusia adalah daging [3]. Makanan pokok bagi sebagian masyarakat Indonesia salah satunya adalah daging. Daging kambing tidak hanya rasanya yang enak tetapi juga kaya akan vitamin[4]. Kambing adalah ruminansia berukuran sedang. Hewan yang banyak dipelihara oleh masyarakat Indonesia karena memiliki banyak manfaat dan dapat meningkatkan perekonomian salah satunya adalah kambing [5]. Kambing merupakan salah satu hewan ternak yang dapat menghasilkan daging yang sehat dan bergizi. Kambing memiliki beberapa keunggulan, antara lain ukurannya yang sedang dan kemudahan perawatannya[6]. Daging kambing relatif rendah lemak dibandingkan daging sapi. Daging kambing terkenal sebagai

sumber protein yang sehat jika dikonsumsi dalam jumlah sedang[7]. Dapat dilihat dibawah ini jumlah produksi daging kambing dari tahun 2001-2022 yang didapat berdasarkan Badan Pusat Statistik Indonesia pada bagian peternakan.



Gambar 1. Grafik Produksi Daging Kambing Di Indonesia

Dapat dilihat pada gambar 1 berdasarkan data Badan Pusat Statistik tentang produksi daging kambing di Indonesia (2001-2022) dijelaskan bahwa produksi daging kambing pada tahun 2001 sebanyak 48.702 ton, tahun 2002 sebanyak 58.170 ton, tahun 2003 sebanyak 63.866 ton, tahun 2004 sebanyak 57.132 ton, tahun 2005 sebanyak 50.607 ton, tahun 2006 sebanyak 65.013ton, tahun 2007 sebanyak 63.615 ton, tahun 2008 sebanyak 66.027 ton, tahun 2009 sebanyak 73.825,34 ton, tahun 2010 sebanyak 68.792,92 ton, tahun 2011 sebanyak 66.345 ton, tahun 2012 sebanyak 66.215 ton, tahun 2013 sebanyak 65.169 ton, tahun 2014 sebanyak 65.142 ton, tahun 2015 sebanyak 64.947,62 ton, tahun 2016 sebanyak 67.844,70 ton, tahun 2017 sebanyak 70.353,52 ton, tahun 2018 sebanyak 70.154,76 ton, tahun 2019 sebanyak 72.852,33 ton, tahun 2020 sebanyak 61.711,22 ton, tahun 2021 sebanyak 59.730,15 ton, tahun 2022 sebanyak 63.658,43 ton. Menurut Badan Pusat Statistik Indonesia, produksi daging kambing mengalami skala produksi yang bervariasi bahkan Indonesia tidak bisa mengeksport daging kambing secara terus menerus. Besarnya kebutuhan daging kambing dapat ditentukan oleh konsumsi daging kambing di Indonesia, konsumsi daging kambing yang tinggi di Indonesia akan memaksa Indonesia mengimpor daging kambing karena kekurangan stok. Harga daging kambing naik dikarenakan kecenderungan impor daging kambing.

Jika jumlah kambing 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[8]. Untuk menstabilkan harga daging kambing dalam waktu dekat, industri peternakan perlu mengetahui berapa banyak daging yang dibutuhkan untuk diproduksi di masa depan [9]. Untuk membuat prediksi diperlukan model dan data dasar untuk melakukan prediksi, sehingga pada saat finalisasi memberikan hasil yang akurat. Dalam mempertimbangkan permasalahan ini, dilakukan analisis dengan menerapkan suatu model prediksi yang sesuai sebagai opsi alternatif dalam memproyeksikan produksi daging kambing. Salah satu alternatif metode yang bisa dipakai untuk memperkirakan produksi daging kambing adalah menggunakan jaringan saraf tiruan dengan metode backpropagation. Teknik ini dapat memecahkan masalah yang kompleks dan terkait dengan proses pengidentifikasian, ramalan, serta pengenalan pola. Berdasarkan riset terdahulu yang melakukan studi perbandingan Algoritma Backpropagation dan *Learning Vektor Quantization* untuk mengenali pola geometri, disimpulkan bahwa Algoritma Back-propagation lebih unggul [10]. Studi sebelumnya juga memperbandingkan dua teknik jaringan saraf tiruan, yakni algoritma back-propagation dan metode learning vector quantization dalam mendeteksi gangguan jantung koroner. Hasilnya menunjukkan bahwa algoritma back-propagation memiliki tingkat ketepatan sebesar 68,76%, sementara metode lvq hanya mencapai akurasi 54%. [11]. Dalam penelitian yang memperbandingkan Back-propagation dengan metode LVQ untuk memverifikasi keaslian uang kertas, Back-propagation menunjukkan tingkat akurasi yang lebih tinggi, mencapai 100%. [12]. Dalam studi perbandingan antara backpropagation dan lvq dalam mengidentifikasi kemampuan mahasiswa baru di Palcomtech, disimpulkan bahwa algoritma backpropagation memiliki tingkat akurasi yang lebih tinggi, yaitu sebesar 99,17%, dibandingkan dengan metode lvq yang hanya mencapai akurasi sebesar 96,67%. [13].

Berdasarkan penelitian sebelumnya yang dilakukan Sabda Zikurillah, 2022[14] mengenai prediksi jumlah produksi daging kambing menghasilkan hasil prediksi dengan metode yang sama. Dalam penelitian sebelumnya, metode yang digunakan untuk membagi data pengerjaan tidak menggunakan pola rotasi, tetapi dengan membagi kedua data tersebut. Namun, pada penelitian yang akan dilakukan, data testing dan training akan dinormalisasi terlebih dahulu sebelum dibagi menggunakan pola rotasi. Selain itu, data juga akan dinormalisasi dengan menggunakan fungsi

sigmoid. Pada penelitian ini hal yang membedakan dengan penelitian sebelumnya adalah penggunaan arsitektur. Di penelitian sebelumnya menggunakan arsitektur 5 – 10. 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 %. Metode backpropagation seringkali digunakan untuk menyelesaikan berbagai permasalahan yang melibatkan prediksi. Penelitian ini bertujuan untuk mengevaluasi kinerja metode backpropagation dalam memprediksi permasalahan tersebut dan menghasilkan hasil terbaik. Dengan demikian, hasil penelitian ini diharapkan dapat memberikan informasi yang bermanfaat bagi pemerintah sektor peternakan dalam mengambil keputusan yang tepat dalam menghadapi permasalahan tersebut di masa depan.

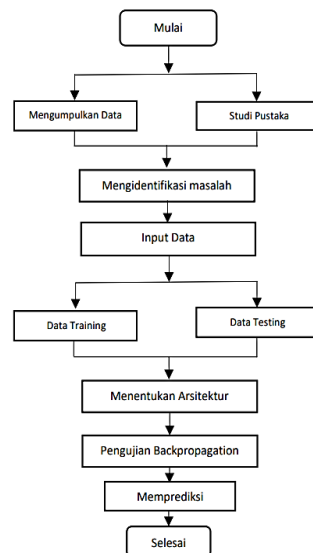
2. METODOLOGI PENELITIAN

2.1 Metode Pengumpulan Data

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/24/482/1/produksi-daging-kambing-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. Dalam penelitian ini, pengumpulan referensi dilakukan melalui studi pustaka dengan cara menentukan jenis pustaka yang akan digunakan terlebih dahulu. Studi pustaka adalah cara pengumpulan informasi dengan membaca literatur seperti buku dan jurnal.

2.2 Kerangka Kerja Penelitian

Pada gambar dibawah dapat dilihat bahwasannya pada proses penelitian 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 latih 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.



Gambar 2. Alur Kerja Penelitian

2.2 Jaringan Saraf Tiruan (JST)

Sistem pemrosesan informasi yang menunjukkan sifat yang mirip dengan jaringan saraf manusia disebut jaringan saraf tiruan [15]-[16]. Model komputer yang diilhami secara biologis, yang terdiri dari banyak elemen saraf juga merupakan jaringan saraf tiruan [17]. *Neural Network* ditentukan oleh tiga factor yaitu arsitektur jaringan, algoritma pembelajaran, dan fungsi aktivasi pernyataan tersebut diungkapkan oleh Fauset pada tahun 1994[18]. Sebagai sekelompok elemen pemrosesan dalam kelompok tertentu, jaringan melakukan perhitungannya sendiri dan meneruskan hasilnya ke kelompok berikutnya [19]. Data non-numerik harus diubah menjadi data numerik dikarenakan algoritma JST bekerja langsung

dengan angka[20]. Pada *Neural Network* pada saat melakukan sebuah proses menggunakan bobot sinaptik untuk menentukan tindakan saraf, kemudian tindakan saraf menentukan keluaran jaringan dan keluaran jaringan menentukan kegalan jaringan [21]. Teknik jaringan saraf tiruan dengan mengatur bobot dan bias pada setiap lapisan jaringan berdasarkan selisih antara hasil prediksi dan nilai tujuan [22]. Salah satu jenis metode yang melakukan pelatihan jaringan saraf tiruan dengan pemeriksaan adalah back-propagation [23]. Ada beberapa jenis layer yang terdapat pada backpropagation diantaranya input layer, hidden layer dan output layer [24]-[25]. Proses backpropagation memiliki dua langkah. Yaitu, proses mengaktifkan atau menyebarkan nilai masukan dan mencocokkannya dengan nilai keluaran yang diinginkan [26]. Metode ini menggunakan nilai error pada output dalam memodifikasi bobot [27]. Pada algoritma *backpropagation* dalam penyelesaian masalah terdapat beberapa langkah-langkah yang digunakan sebagai berikut [28]-[29]:

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

$$Z_{inj} = V0j + \sum_i^n 1 X_i V_{ij} \quad (1)$$

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

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

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

$$y_{ink} = V0k + \sum_k^p 1 Z_j W_{jk} \quad (3)$$

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

$$y_k = \frac{1}{1+e^{-y_{ink}}}$$

Tahap Algoritma *backpropagation*

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

c. 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 Mengidentifikasi Masalah

Dalam menjalankan studi, dibutuhkan proses identifikasi yang tepat. Identifikasi masalah pada studi meliputi akar penyebab masalah serta perumusan pernyataan masalah yang terperinci dan mencakup efek masalah. Tanpa identifikasi masalah yang akurat, hasil studi dapat mudah disalahkan. Identifikasi masalah juga memerlukan pemahaman yang mendalam terhadap sifat masalah untuk mendapatkan solusi yang sesuai dalam menyelesaikan masalah.

3.2 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 kambing pada penelitian ini menggunakan data pada tahun 2002-2022. Data tersebut yang akan menjadi panduan dalam pengambilan keputusan dalam pengambilan keputusan ketika melakukan suatu prediksi dengan menggunakan algoritma backpropagation. Penetapan input pada penelitian ini dibagi menjadi data *training* dan data *testing*. Pada penelitian ini memiliki beberapa jumlah input yang mana dapat dilihat pada tabel 1. dibawah ini. Tabel 1. Menjelaskan bahwasannya input yang terdapat pada penelitian ini memiliki 21 variabel dengan variable X1 sampai variable X22. Pada setiap variable memiliki kriterianya masing-masing.

Tabel 1. Daftar Input Data Produksi Daging Kambing

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

No	Variabel	Nama Kriteria
9	X9	2009
10	X10	2010
11	X11	2011
12	X12	2012
13	X13	2013
14	X14	2014
15	X15	2015
16	X16	2016
17	X17	2017
18	X18	2018
19	X19	2019
20	X20	2020
21	X21	2021
22	x22	2022

3.3 Penetapan Output

Pada penelitian ini tahap yang sangat diharapkan adalah tahap dalam menentukan nilai yang terbaik pada saat memprediksi jumlah daging kambing pada tahun 2023. Agar mendapatkan hasil jumlah prediksi membutuhkan arsitektur terbaik dengan cara melihat nilai error minimum. Pada penelitian ini menggunakan nilai error minimum ≤ 0.05 dengan nilai benar(1) dan lebih dari 0.05 dengan nilai salah(0). Semakin kecil error minimum yang di dapat maka sebuah penelitian lebih baik.

3.4 Pengolahan Data Latih

Data produksi daging kambing di Indonesia tahun 2001-2022 digunakan untuk penelitian ini. Data yang diperoleh dari Badan Pusat Statistik sebelum implementasi aplikasi Matlab terlebih dahulu dinormalisasi dengan fungsi sigmoid (tidak mencapai 0 atau 1) dengan Excel. Pada penelitian ini data yang telah dinormalisasi dengan menggunakan fungsi sigmoid akan dibagi menjadi dua bagian yaitu data latih dan data uji. Pada artikel ini data latih dimulai pada tahun 2001-2021 dan data uji dimulai pada tahun 2002-2022. Sebelum pembagian data latih dan data uji data di normalisasi terlebih dahulu. Sehingga normalisasi data dapat direpresentasikan dengan persamaan berikut [21]:

$$X1 = \frac{0.8(x-min)}{max-min} + 0.1 \quad (4)$$

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

No	Provinsi	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011
1	Aceh	0.1514	0.1506	0.1508	0.1521	0.1487	0.1546	0.2660	0.1434	0.1418	0.1444	0.1517
2	Sumut	0.1775	0.1780	0.1792	0.1674	0.1877	0.1735	0.2475	0.2045	0.1794	0.1855	0.2029
3	Sumbar	0.1339	0.1276	0.1484	0.1797	0.1393	0.1293	0.1381	0.1465	0.1598	0.1741	0.1244
4	Riau	0.1322	0.1301	0.1182	0.1172	0.1135	0.1283	0.1467	0.1408	0.1370	0.1789	0.1253
5	Jambi	0.1070	0.1053	0.1072	0.1084	0.1095	0.1066	0.1106	0.1159	0.1140	0.1148	0.1187
6	Sumsel	0.1222	0.1312	0.1301	0.1333	0.1333	0.1677	0.1404	0.1535	0.1635	0.1650	0.1372
7	Bengkulu	0.1194	0.1204	0.1090	0.1129	0.1082	0.1070	0.1063	0.1068	0.1048	0.1057	0.1075
8	Lampung	0.1468	0.1470	0.1600	0.1624	0.1630	0.1882	0.1815	0.2719	0.2720	0.1485	0.1685
9	Bangka belitung	0.1000	0.1018	0.1052	0.1008	0.1006	0.1015	0.1015	0.1010	0.1014	0.1028	0.1031
10	Dki jakarta	0.1434	0.1368	0.1583	0.1276	0.1335	0.1370	0.1275	0.1317	0.1265	0.1310	0.1417
11	Jawa barat	0.2557	0.4367	0.3525	0.3513	0.2281	0.3211	0.2904	0.3331	0.4616	0.2812	0.2468
12	Jawa tengah	0.3901	0.4634	0.4933	0.4447	0.3811	0.5261	0.3614	0.4044	0.4360	0.4730	0.5083
13	Yogyakarta	0.1296	0.1290	0.1283	0.1338	0.1362	0.1903	0.1273	0.1302	0.1232	0.1225	0.1368
14	Jawa timur	0.4478	0.4649	0.5451	0.5501	0.5541	0.5597	0.5828	0.5901	0.6479	0.6484	0.6338
15	Banten	0.2247	0.2282	0.3414	0.1497	0.1729	0.1414	0.1948	0.2188	0.2126	0.2206	0.2105
16	Bali	0.1432	0.1719	0.1509	0.1563	0.1474	0.1757	0.1372	0.1431	0.1508	0.1491	0.1542
17	NTB	0.1190	0.1183	0.1202	0.1256	0.1228	0.1463	0.1578	0.1084	0.1946	0.2183	0.2457

No	Provinsi	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011
18	NTT	0.1400	0.1423	0.1437	0.1447	0.1540	0.1837	0.1775	0.1924	0.1835	0.1640	0.1343
19	Kalimantan barat	0.1098	0.1095	0.1094	0.1073	0.1086	0.1154	0.1151	0.1156	0.1207	0.1193	0.1285
20	Kalimantan tengah	0.1035	0.1029	0.1073	0.1053	0.1055	0.1022	0.1183	0.1191	0.1051	0.1068	0.1041
21	Kalimantan selatan	0.1061	0.1045	0.1089	0.1115	0.1087	0.1129	0.1098	0.1130	0.1141	0.1211	0.1232
22	Kalimantan timur	0.1136	0.1151	0.1169	0.1179	0.1177	0.1180	0.1208	0.1181	0.1194	0.1190	0.1187
23	Sulawesi utara	0.1093	0.1097	0.1098	0.1107	0.1203	0.1366	0.1121	0.1118	0.1118	0.1119	0.1120
24	Sulawesi tengah	0.1465	0.1441	0.1491	0.1462	0.1264	0.1260	0.1185	0.1312	0.1206	0.1213	0.1323
25	Sulawesi selatan	0.1077	0.1093	0.1043	0.1171	0.1062	0.1180	0.1223	0.1239	0.1182	0.1277	0.1282
26	Sulawesi tenggara	0.1183	0.1156	0.1159	0.1162	0.1093	0.1072	0.1084	0.1173	0.1171	0.1176	0.1186
27	Gorontalo	0.1004	0.1011	0.1018	0.1000	0.1027	0.1001	0.1081	0.1036	0.1036	0.1052	0.1096
28	Maluku	0.1220	0.1220	0.1237	0.1264	0.1222	0.1415	0.1013	0.1263	0.1323	0.1348	0.1375
29	Maluku utara	0.1058	0.1041	0.1169	0.1169	0.1125	0.1117	0.1426	0.1237	0.1269	0.1323	0.1007
30	Papua	0.1032	0.1076	0.1031	0.1028	0.1023	0.1036	0.1028	0.1038	0.1032	0.1033	0.1034

Tabel 3. Lanjutan Data *training* setelah dinormalisasi

No	Provinsi	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
1	Aceh	0.1519	0.1701	0.1948	0.1820	0.1877	0.1853	0.1894	0.1695	0.1612	0.1629
2	Sumut	0.2056	0.2093	0.2114	0.2117	0.2247	0.2254	0.1381	0.1351	0.1266	0.1282
3	Sumbar	0.1234	0.1202	0.1209	0.1214	0.1216	0.1235	0.1258	0.1224	0.1213	0.1125
4	Riau	0.1145	0.1171	0.1193	0.1202	0.1204	0.1228	0.1259	0.1214	0.1180	0.1232
5	Jambi	0.1186	0.1225	0.1215	0.1205	0.1237	0.1251	0.1406	0.1518	0.1308	0.1219
6	Sumbar	0.1382	0.1699	0.1481	0.1408	0.1438	0.1587	0.1629	0.1538	0.1453	0.1554
7	Bengkulu	0.1097	0.1076	0.1135	0.1171	0.1079	0.1028	0.1029	0.1028	0.1035	0.1033
8	Lampung	0.1757	0.1776	0.1636	0.1568	0.1663	0.1665	0.1573	0.1679	0.1839	0.2345
9	Bangka belitung	0.1022	0.1030	0.1028	0.1027	0.1016	0.1022	0.1026	0.1022	0.1030	0.1052
10	Dki jakarta	0.1318	0.1396	0.1355	0.1272	0.1348	0.1379	0.1408	0.1263	0.1250	0.1221
11	Jawa barat	0.2835	0.3257	0.3485	0.3672	0.3328	0.3963	0.4196	0.3295	0.2825	0.1787
12	Jawa tengah	0.4639	0.4220	0.4524	0.4485	0.4680	0.4739	0.4727	0.4957	0.4942	0.4898
13	Di yogyakarta	0.1200	0.1468	0.1466	0.1502	0.1519	0.1679	0.1503	0.1604	0.1560	0.1439
14	Jawa timur	0.6325	0.5888	0.6243	0.6193	0.6662	0.6892	0.7791	0.9000	0.7206	0.7355
15	Banten	0.2160	0.2022	0.1810	0.2102	0.1723	0.1801	0.2122	0.2479	0.1966	0.1721
16	Bali	0.1408	0.1528	0.1543	0.1818	0.2072	0.1917	0.1269	0.1282	0.1542	0.1614
17	Nusa Tenggara Barat	0.2533	0.1121	0.1065	0.1056	0.1068	0.1085	0.1083	0.1094	0.1118	0.1122
18	Nusa Tenggara Timur	0.1203	0.2143	0.2174	0.1545	0.1554	0.1635	0.1663	0.1766	0.1232	0.1274
19	Kalimantan barat	0.1147	0.1160	0.1085	0.1081	0.1111	0.1144	0.1128	0.1129	0.1119	0.1113
20	Kalimantan tengah	0.1099	0.1105	0.1097	0.1106	0.1063	0.1061	0.1068	0.1066	0.1070	0.1071
21	Kalimantan selatan	0.1228	0.1207	0.1204	0.1176	0.1172	0.1137	0.1112	0.1098	0.1070	0.1109
22	Kalimantan timur	0.1140	0.1127	0.1166	0.1137	0.1155	0.1182	0.1194	0.1173	0.1178	0.1237
23	Sulawesi utara	0.1120	0.1122	0.1122	0.1123	0.1074	0.1057	0.1057	0.1057	0.1047	0.1026
24	Sulawesi tengah	0.1475	0.1774	0.1474	0.1505	0.1900	0.1425	0.1350	0.1438	0.1548	0.1541
25	Sulawesi selatan	0.1526	0.1500	0.1299	0.1304	0.1326	0.1321	0.1353	0.1348	0.1239	0.1274
26	Sulawesi tenggara	0.1061	0.1081	0.1037	0.1098	0.1098	0.1113	0.1110	0.1096	0.1100	0.1063
27	Gorontalo	0.1039	0.1054	0.1019	0.1048	0.1060	0.1082	0.1098	0.1077	0.1084	0.1085
28	Maluku	0.1403	0.1140	0.1062	0.1051	0.1106	0.1066	0.1060	0.1073	0.1073	0.1078
29	Maluku utara	0.1016	0.1009	0.1007	0.1029	0.1036	0.1034	0.1039	0.1024	0.1033	0.1024
30	Papua	0.1035	0.1039	0.1056	0.1066	0.1072	0.1087	0.1083	0.1082	0.1075	0.1054

Dapat dilihat dari 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.

Tabel 4. Data pengujian (*testing*) setelah dinormalisasi

No	Provinsi	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012
1	Aceh	0.1506	0.1508	0.1520	0.1487	0.1545	0.2660	0.1434	0.1418	0.1443	0.1516	0.1519

No	Provinsi	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012
2	Sumatera utara	0.1779	0.1792	0.1674	0.1877	0.1735	0.2474	0.2045	0.1794	0.1855	0.2029	0.2056
3	Sumatera barat	0.1276	0.1484	0.1797	0.1393	0.1293	0.1381	0.1464	0.1597	0.1741	0.1244	0.1234
4	Riau	0.1300	0.1182	0.1172	0.1135	0.1283	0.1466	0.1408	0.1370	0.1789	0.1253	0.1145
5	Jambi	0.1052	0.1071	0.1083	0.1095	0.1066	0.1106	0.1158	0.1139	0.1148	0.1186	0.1186
6	Sumatera selatan	0.1312	0.1301	0.1332	0.1332	0.1677	0.1403	0.1535	0.1635	0.1650	0.1372	0.1382
7	Bengkulu	0.1203	0.1089	0.1129	0.1081	0.1070	0.1062	0.1068	0.1047	0.1057	0.1075	0.1096
8	Lampung	0.1470	0.1600	0.1624	0.1630	0.1882	0.1814	0.2719	0.2720	0.1485	0.1685	0.1757
9	Bangka belitung	0.1018	0.1051	0.1007	0.1006	0.1014	0.1014	0.1009	0.1013	0.1028	0.1031	0.1022
10	Dki jakarta	0.1368	0.1583	0.1275	0.1334	0.1370	0.1275	0.1317	0.1265	0.1310	0.1417	0.1318
11	Jawa barat	0.4367	0.3525	0.3513	0.2281	0.3210	0.2904	0.3330	0.4616	0.2812	0.2468	0.2835
12	Jawa tengah	0.4634	0.4932	0.4446	0.3811	0.5261	0.3614	0.4044	0.4360	0.4730	0.5083	0.4639
13	Di yogyakarta	0.1290	0.1283	0.1338	0.1362	0.1903	0.1273	0.1301	0.1232	0.1224	0.1368	0.1200
14	Jawa timur	0.4649	0.5451	0.5500	0.5540	0.5597	0.5828	0.5901	0.6479	0.6484	0.6338	0.6325
15	Banten	0.2282	0.3414	0.1497	0.1729	0.1413	0.1948	0.2187	0.2125	0.2206	0.2105	0.2160
16	Bali	0.1719	0.1509	0.1562	0.1473	0.1756	0.1372	0.1431	0.1507	0.1491	0.1542	0.1408
17	NTB	0.1183	0.1202	0.1255	0.1228	0.1462	0.1578	0.1084	0.1946	0.2183	0.2456	0.2533
18	NTT	0.1423	0.1437	0.1447	0.1540	0.1837	0.1774	0.1924	0.1835	0.1640	0.1342	0.1203
19	Kalimantan barat	0.1094	0.1094	0.1073	0.1086	0.1154	0.1151	0.1155	0.1207	0.1193	0.1285	0.1147
20	Kalimantan tengah	0.1029	0.1073	0.1053	0.1054	0.1022	0.1183	0.1191	0.1051	0.1067	0.1041	0.1098
21	Kalimantan Selatan	0.1045	0.1088	0.1115	0.1086	0.1129	0.1098	0.1130	0.1141	0.1211	0.1231	0.1228
22	Kalimantan timur	0.1151	0.1169	0.1179	0.1177	0.1180	0.1208	0.1180	0.1194	0.1190	0.1187	0.1140
23	Sulawesi utara	0.1097	0.1097	0.1106	0.1203	0.1366	0.1120	0.1118	0.1118	0.1118	0.1120	0.1120
24	Sulawesi tengah	0.1441	0.1491	0.1462	0.1264	0.1260	0.1184	0.1312	0.1206	0.1212	0.1323	0.1475
25	Sulawesi selatan	0.1093	0.1042	0.1171	0.1062	0.1180	0.1222	0.1239	0.1182	0.1277	0.1282	0.1526
26	Sulawesi tenggara	0.1156	0.1158	0.1162	0.1093	0.1072	0.1084	0.1172	0.1170	0.1176	0.1186	0.1061
27	Gorontalo	0.1010	0.1017	0.1000	0.1027	0.1001	0.1081	0.1036	0.1036	0.1052	0.1096	0.1038
28	Maluku	0.1219	0.1237	0.1264	0.1222	0.1415	0.1012	0.1263	0.1323	0.1348	0.1375	0.1403
29	Maluku utara	0.1041	0.1169	0.1169	0.1125	0.1116	0.1425	0.1237	0.1269	0.1323	0.1007	0.1016
30	Papua	0.1076	0.1030	0.1028	0.1022	0.1035	0.1027	0.1037	0.1032	0.1033	0.1034	0.1035

Dari tabel 4 diatas dapat dilihat bahwasannya menunjukkan data pengujian yang telah dinormalisasi dengan menggunakan fungsi sigmoid. Dapat dilihat pada tabel dibawah ini juga menunjukkan hasil lanjutan data pengujian yang telah dinormalisasi yang nantinya akan digunakan dalam proses pengujian data dengan mengimplementasikan ke aplikasi matlab. Pada penelitian ini menggunakan versi 7 R2011a. Data pengujian pada penelitian dalam memprediksi jumlah produksi daging kambing ini diambil dari data peternakan Badan Pusat Statistik Indonesia dan data yang digunakan pada pengujian ini adalah data mulai tahun 2002-2022. Data tahun 2022 dijadikan sebagai target. Data pengujian ini memiliki data dengan satuan Ton.

Tabel 5. Lanjutan data pengujian (*testing*) setelah dinormalisasi

No	Provinsi	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022
1	Aceh	0.1701	0.1948	0.1819	0.1877	0.1853	0.1894	0.1695	0.1612	0.1629	0.1643
2	Sumatera utara	0.2092	0.2114	0.2116	0.2247	0.2254	0.1380	0.1350	0.1265	0.1282	0.1290
3	Sumatera barat	0.1201	0.1209	0.1214	0.1216	0.1235	0.1258	0.1224	0.1213	0.1125	0.1125
4	Riau	0.1171	0.1193	0.1202	0.1203	0.1228	0.1258	0.1214	0.1180	0.1231	0.1234
5	Jambi	0.1225	0.1215	0.1205	0.1237	0.1251	0.1406	0.1518	0.1308	0.1219	0.1204
6	Sumatera selatan	0.1699	0.1481	0.1408	0.1438	0.1587	0.1628	0.1538	0.1452	0.1554	0.1586
7	Bengkulu	0.1075	0.1135	0.1170	0.1079	0.1027	0.1029	0.1027	0.1035	0.1033	0.1053
8	Lampung	0.1776	0.1636	0.1568	0.1663	0.1665	0.1572	0.1678	0.1838	0.2345	0.2401
9	Bangka belitung	0.1029	0.1028	0.1027	0.1015	0.1022	0.1026	0.1021	0.1030	0.1051	0.1054
10	Dki jakarta	0.1396	0.1355	0.1272	0.1348	0.1379	0.1408	0.1263	0.1249	0.1220	0.1246
11	Jawa barat	0.3257	0.3485	0.3672	0.3328	0.3963	0.4196	0.3295	0.2825	0.1786	0.2736
12	Jawa tengah	0.4220	0.4523	0.4484	0.4680	0.4739	0.4727	0.4957	0.4942	0.4897	0.4689
13	Di yogyakarta	0.1468	0.1465	0.1502	0.1519	0.1679	0.1503	0.1603	0.1560	0.1439	0.1443
14	Jawa timur	0.5888	0.6243	0.6193	0.6662	0.6892	0.7791	0.9000	0.7206	0.7355	0.7514
15	Banten	0.2022	0.1810	0.2101	0.1723	0.1801	0.2122	0.2479	0.1966	0.1721	0.1821
16	Bali	0.1527	0.1543	0.1818	0.2071	0.1916	0.1268	0.1282	0.1542	0.1614	0.1623

No	Provinsi	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022
17	Nusa tenggara barat	0.1121	0.1065	0.1056	0.1068	0.1084	0.1083	0.1094	0.1118	0.1121	0.1128
18	Nusa tenggara timur	0.2143	0.2174	0.1544	0.1554	0.1634	0.1662	0.1765	0.1231	0.1274	0.1302
19	Kalimantan barat	0.1160	0.1085	0.1081	0.1110	0.1144	0.1127	0.1129	0.1119	0.1112	0.1114
20	Kalimantan tengah	0.1104	0.1097	0.1106	0.1062	0.1061	0.1068	0.1065	0.1070	0.1071	0.1072
21	Kalimantan selatan	0.1207	0.1204	0.1176	0.1171	0.1137	0.1112	0.1098	0.1069	0.1108	0.1103
22	Kalimantan timur	0.1127	0.1166	0.1137	0.1155	0.1182	0.1194	0.1173	0.1178	0.1237	0.1241
23	Sulawesi utara	0.1121	0.1122	0.1123	0.1074	0.1056	0.1056	0.1057	0.1046	0.1026	0.1027
24	Sulawesi tengah	0.1774	0.1474	0.1505	0.1900	0.1425	0.1350	0.1438	0.1547	0.1541	0.1548
25	Sulawesi selatan	0.1500	0.1299	0.1304	0.1325	0.1320	0.1352	0.1347	0.1238	0.1274	0.1275
26	Sulawesi tenggara	0.1081	0.1037	0.1098	0.1098	0.1113	0.1110	0.1096	0.1100	0.1062	0.1061
27	Gorontalo	0.1054	0.1019	0.1047	0.1060	0.1081	0.1098	0.1077	0.1084	0.1085	0.1089
28	Maluku	0.1139	0.1062	0.1051	0.1105	0.1066	0.1059	0.1072	0.1073	0.1078	0.1100
29	Maluku utara	0.1009	0.1006	0.1029	0.1036	0.1033	0.1039	0.1023	0.1033	0.1024	0.1024
30	Papua	0.1039	0.1056	0.1066	0.1071	0.1086	0.1083	0.1082	0.1074	0.1054	0.1056

3.5 Perancangan Arsitektur Dan Pengujian Backpropagation

Setelah melakukan pengolahan data dengan menggunakan fungsi sigmoid maka sekarang akan dilakukan proses perancangan arsitektur dengan menggunakan aplikasi matlab. Pada penelitian ini sebuah perancangan arsitektur menggunakan sebuah aplikasi matlab R2011a. Pada penelitian ini penulis menggunakan beberapa arsitektur jaringan. Dari hasil pengujian yang telah dilakukan maka didapatkan sebuah arsitektur terbaik dengan akurasi tertinggi yaitu arsitektur 20-15-1 dengan MSE pelatihan 0.00100037 dengan akurasi sebesar 93% dan MSE pengujian 0.00262384 dengan akurasi 90% dan mempunyai epoch 27915 iterations. Dapat dilihat hasil dari arsitektur 20-15-1 pada tabel dibawah ini. Dapat dilihat pada tabel dibawah ini bahwasannya output dan error diperoleh beraskan dari implementasi pada aplikasi matlab, *SSE* diperoleh dari hasil error dan \wedge^2 lalu penentuan jumlah *MSE* didapatkan dari jumlah *sse* dibagi dengan jumlah yang ada pada data. Untuk mendapatkan nilai akurasi didapat apabila nilai error ≤ 0.05 maka memiliki nilai 1(benar), dan apabila memiliki nilai ≥ 0.05 memiliki nilai 0 atau bernilai salah. Sehingga jumlah nilai kebenaran akurasi dibagi dengan banyaknya data yang diolah sehingga memperoleh seberapa besar keakuratan arsitektur tersebut.

Tabel 6. Hasil Data pelatihan arsitektur terbaik

No	Provinsi	Output	Error	SSE	Akurasi
1	Aceh	0.1215	0.0414	0.00171396	1
2	Sumatera utara	0.154	-0.0258	0.00066564	1
3	Sumatera barat	0.0954	0.0171	0.00029241	1
4	Riau	0.1132	0.01	0.00010000	1
5	Jambi	0.1342	-0.0123	0.00015129	1
6	Sumatera selatan	0.1218	0.0336	0.00112896	1
7	Bengkulu	0.1306	-0.0274	0.00075076	1
8	Lampung	0.1086	0.1259	0.01585081	0
9	Kep. Bangka belitung	0.1317	-0.0266	0.00070756	1
10	Dki jakarta	0.1238	-0.0017	0.00000289	1
11	Jawa barat	0.2098	-0.0311	0.00096721	1
12	Jawa tengah	0.489	0.0008	0.00000064	1
13	Di yogyakarta	0.1245	0.0194	0.00037636	1
14	Jawa timur	0.7366	-0.0011	0.00000121	1
15	Banten	0.1195	0.0526	0.00276676	0
16	Bali	0.1335	0.0279	0.00077841	1
17	Nusa tenggara barat	0.1061	0.0061	0.00003721	1
18	Nusa tenggara timur	0.1304	-0.0029	0.00000841	1
19	Kalimantan barat	0.1263	-0.015	0.00022500	1
20	Kalimantan tengah	0.1295	-0.0224	0.00050176	1
21	Kalimantan selatan	0.1358	-0.0249	0.00062001	1
22	Kalimantan timur	0.1226	0.0011	0.00000121	1
23	Sulawesi utara	0.1232	-0.0206	0.00042436	1
24	Sulawesi tengah	0.1455	0.0086	0.00007396	1
25	Sulawesi selatan	0.1432	-0.0158	0.00024964	1
26	Sulawesi tenggara	0.1224	-0.0161	0.00025921	1

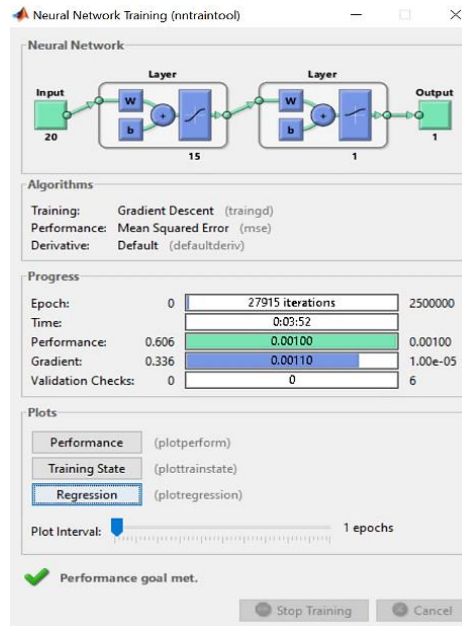
No	Provinsi	Output	Error	SSE	Akurasi
27	Gorontalo	0.131	-0.0225	0.00050625	1
28	Maluku	0.1174	-0.0096	0.00009216	1
29	Maluku utara	0.1077	-0.0053	0.00002809	1
30	Papua	0.1324	-0.027	0.00072900	1
Jlh SSE				0.03001114	93%
MSE				0.00100037	

Dapat dilihat dari tabel 7 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 7. Hasil data pengujian arsitektur terbaik

No	Provinsi	Output	Error	SSE	Akurasi
1	Aceh	0.1303	0.0340	0.00115600	1
2	Sumatera utara	0.1273	0.0018	0.00000324	1
3	Sumatera barat	0.1004	0.0122	0.00014884	1
4	Riau	0.1083	0.0151	0.00022801	1
5	Jambi	0.1353	-0.0149	0.00022201	1
6	Sumatera selatan	0.125	0.0336	0.00112896	1
7	Bengkulu	0.1311	-0.0258	0.00066564	1
8	Lampung	0.1043	0.1358	0.01844164	0
9	Kep. Bangka belitung	0.1318	-0.0264	0.00069696	1
10	Dki jakarta	0.126	-0.0014	0.00000196	1
11	Jawa barat	0.2496	0.0240	0.00057600	1
12	Jawa tengah	0.3312	0.1377	0.01896129	0
13	Di yogyakarta	0.1339	0.0104	0.00010816	1
14	Jawa timur	0.5727	0.1787	0.03193369	0
15	Banten	0.1863	-0.0042	0.00001764	1
16	Bali	0.1334	0.0289	0.00083521	1
17	Nusa tenggara barat	0.1023	0.0105	0.00011025	1
18	Nusa tenggara timur	0.1261	0.0041	0.00001681	1
19	Kalimantan barat	0.1248	-0.0134	0.00017956	1
20	Kalimantan tengah	0.1276	-0.0204	0.00041616	1
21	Kalimantan selatan	0.1316	-0.0213	0.00045369	1
22	Kalimantan timur	0.1219	0.0022	0.00000484	1
23	Sulawesi utara	0.1229	-0.0202	0.00040804	1
24	Sulawesi tengah	0.1427	0.0122	0.00014884	1
25	Sulawesi selatan	0.1413	-0.0138	0.00019044	1
26	Sulawesi tenggara	0.1239	-0.0179	0.00032041	1
27	Gorontalo	0.1314	-0.0224	0.00050176	1
28	Maluku	0.1128	-0.0028	0.00000784	1
29	Maluku utara	0.1104	-0.0080	0.00006400	1
30	Papua	0.1333	-0.0277	0.00076729	1
Jlh SSE				0.07871518	90%
MSE				0.00262384	

Dari gambar 3 dijelaskan bahwa model arsitektur 20-15-1 telah memperoleh Epoch dengan 27915 iterations dalam waktu 3 menit 52 detik dan memperoleh performance goal dengan nilai 0.00100. Pada artikel ini untuk pengaplikasian pada aplikasi matlab dalam perancangan arsitektur jaringan menggunakan *Train Gradient Descent* "training".



Gambar 3. Pelatihan Arsitektur 20-15-1

Pada tabel 7 menunjukkan prediksi jumlah daging kambing yang akan diproduksi dapat dilihat bahwa data real diperoleh dari data awal sebelum dinormalisasi pada tahun terakhir, data target diambil dari target testing, data target prediksi diambil berdasarkan output yang didapat pada arsitektur terbaik. Data pada tabel prediksi dibawah ini dicari dengan cara menghitung data target prediksi dikurang dengan 0,1(interval) dikali dengan hasil dari nilai maximum dikurang minimum pada data real lalu dibagi dengan 0,8(interval) dan ditambah dengan nilai minimum pada data real sehingga dihasilkan data prediksi. Tabel dibawah ini menunjukkan hasil sementara untuk daging yang harus diproduksi pada tahun kedepannya agar dapat mengatasi permasalahan diatas.

Tabel 7. Hasil Prediksi Daging Kambing Tahun 2023

No	Provinsi	Data Real	Target	Target Prediksi	Prediksi
1	Aceh	2046.43	0.164323	0.1303	862.275
2	Sumatera utara	927.47	0.129014	0.1273	785.1428
3	Sumatera barat	405.3	0.112537	0.1004	93.52429
4	Riau	748.8	0.123376	0.1083	296.639
5	Jambi	653.48	0.120368	0.1353	990.8286
6	Sumatera selatan	1866.11	0.158633	0.125	726.0081
7	Bengkulu	176.23	0.105309	0.1311	882.8435
8	Lampung	4447.92	0.240102	0.1043	193.7961
9	Kep. Bangka belitung	178.86	0.105391	0.1318	900.8411
10	Dki jakarta	788.54	0.12463	0.126	751.7189
11	Jawa barat	5509.13	0.273588	0.2496	3929.564
12	Jawa tengah	11699.54	0.468927	0.3312	6027.56
13	Di yogyakarta	1412.03	0.144304	0.1339	954.8336
14	Jawa timur	20651.82	0.751417	0.5727	12236.7
15	Banten	2610.69	0.182128	0.1863	2302.076
16	Bali	1982.55	0.162307	0.1334	941.9782
17	Nusa tenggara barat	412.48	0.112763	0.1023	142.3747
18	Nusa tenggara timur	965.11	0.130202	0.1261	754.2899
19	Kalimantan barat	369.23	0.111399	0.1248	720.866
20	Kalimantan tengah	236.24	0.107202	0.1276	792.856
21	Kalimantan selatan	333.96	0.110286	0.1316	895.6989
22	Kalimantan timur	772.61	0.124127	0.1219	646.3049
23	Sulawesi utara	92.93	0.10268	0.1229	672.0156
24	Sulawesi tengah	1746.02	0.154843	0.1427	1181.088
25	Sulawesi selatan	881	0.127548	0.1413	1145.093
26	Sulawesi tenggara	200.88	0.106086	0.1239	697.7263

No	Provinsi	Data Real	Target	Target Prediksi	Prediksi
27	Gorontalo	290.73	0.108922	0.1314	890.5568
28	Maluku	324.49	0.109987	0.1128	412.3373
29	Maluku utara	83.24	0.102374	0.1104	350.6315
30	Papua	186.63	0.105637	0.1333	939.4071

3.6 Rekapitulasi Arsitektur

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 20-15-1 dengan hasil *Mean Squared Error* pelatihan 0.001000371 dan *Mean Squared Error* pengujian 0.002623839 dalam waktu 03 menit 52 detik pada epoch 27915 iterations. Pada saat menentukan jumlah *Mean Squared Error* Dibutuhkan seluruh jumlah SSE terlebih dahulu yang mana jumlah SSE didapat dari hasil error pada matlab dan dipangkatkan sehingga seluruh jumlah SSE di bagi seluruh data dan kemudian mendapatkan hasil *Mean Squared Error* Tabel 8 dibawah ini menunjukkan arsitektur yang telah diuji. Dapat dilihat pada tabel 8 dibawah ini bahwasannya akurasi pelatihan dapat lebih baik dibandingkan dengan akurasi pengujian.

Tabel 8. Rekapitulasi Hasil Arsitektur

Arsitektur	Epoch	Waktu	MSE Pelatihan	Akurasi	MSE Pengujian	Akurasi
20-15-1	27915 Iterations	03: 52 Detik	0.001000371	93%	0.002623839	90%
20-25-1	16727 Iterations	02:02 Detik	0.00099990	93%	0.00447765	77%
20-30-1	5654 Iterations	00: 40 Detik	0.00100031	80%	0.00300466	80%
20-35-1	15395 Iterations	01: 54 Detik	0.00099992	93%	0.00426823	77%
20-37-1	10344 Iterations	01: 17 Detik	0.00099972	90%	0.00357757	83%

4. KESIMPULAN

Dari hasil penelitian yang telah dilakukan dapat diambil kesimpulan bahwa dengan mengimplementasikan jaringan saraf tiruan dengan metode *backpropagation* dapat disimpulkan dapat diterapkan dalam melakukan prediksi dalam menganalisa jumlah prediksi daging kambing yang akan diproduksi. Metode *backpropagation* melakukan pelatihan pada lapisan tersembunyi dengan beberapa varian model neuron terbaik. Pada artikel ini mengaplikasikan 5 arsitektur jaringan yang diimplementasikan pada aplikasi matlab. 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. Pada penelitian ini dalam menentukan sebuah arsitektur yang terbaik kriteria pertama dapat dilihat dari *Mean Squared Error* yang ditemukan apabila *Mean Squared Error* tersebut paling kecil maka masuk pada kriteria pertama, pada kriteria kedua akurasi yang telah ditemukan apabila lebih dari 75 % maka akan masuk pada kriteria kedua, sementara pada kriteria akhir ditentukan pada epoch yang didapat. Melatih jaringan saraf tiruan pada kumpulan data dalam jumlah besar memerlukan perhitungan yang rumit. Oleh karena itu, jaringan saraf tiruan dengan arsitektur jaringan sederhana kurang efisien dan dapat diatasi dengan menambah jumlah neuron pada lapisan tersembunyi. Dari sini dapat disimpulkan bahwa metode *backpropagation* dapat mengatasi permasalahan yang telah dijelaskan sebelumnya. Penulis dapat memberikan saran kepada penelitian bahwa normalisasi data perlu dilakukan dengan formula yang lebih akurat untuk mendapatkan hasil normalisasi yang sesuai, sehingga proses pengolahan dalam peramalan data dapat lebih ditingkatkan atau dikembangkan. Produksi daging kambing di masa depan. Saran yang diberikan adalah penelitian selanjutnya dapat menghasilkan akurasi yang lebih baik dari penelitian sebelumnya, dan diharapkan informasi yang lebih banyak dapat dikumpulkan pada penelitian yang akan datang. Ini berguna untuk memungkinkan jaringan mengenali pola data dengan lebih baik dan mencapai akurasi yang lebih tinggi dan eror yang lebih kecil. Dikarenakan semakin kecil eror yang didapatkan maka semakin bagus hasil tersebut.

REFERENCES

- [1] v. Rinata, a. Witjoro, a. Jalaluddin, and m. S. Amrilah, "profil inkubasi bisnis peternakan kambing berbasis smart-warehouse terkonep plecs sebagai strategi optimalisasi potensi bisnis di rural area," vol. 2, no. 1, pp. 76–86, 2022.
- [2] a. Eka, a. Juarna, t. Informatika, f. T. Industri, and u. Gunadarma, "prediksi pro duksi daging sapi nasional dengan meto de regresi linier dan regresi polinomial," j. Ilm. Komputasi, vol. 20, no. 2, pp. 209–215, 2021, doi: 10.32409/jikstik.20.2.2722.
- [3] z. Febriana and d. Mellinia, "implementasi model cnn dan tensorflow dalam pendeteksian jenis daging hewan ternak," vol. 9, no. 1, pp. 54–61, 2022.
- [4] m. Bramasta, p. Agung bayupati, and d. Made, "klasifikasi citra daging menggunakan deep learning dengan optimisasi hard voting," j. Resti (rekayasa sist. Dan teknol. Informasi), vol. 5, no. 4, pp. 656–662, 2021, doi: 10.29207/resti.v5i4.3247.
- [5] a. Primawati, i. Mutia, and d. Marlina, "analisis klasifikasi populasi ternak kambing dan domba dengan model convolutional

- neural network,” vol. 14, no. 1, pp. 22–33, 2021, doi: 10.30998/faktorexacta.v14i1.8734.
- [6] z. Y. Budiarto, agus. Ciptadi, gatot.ardyah, ramadhina, satria, “tingkat pemotongan kambing lokal betina (pio-p11) di kluster tph swasta kediri,” vol. 22, no. 1, pp. 63–68, 2021, doi: 10.21776/ub.jtapro.2021.022.01.8.
- [7] p. Alicia, “sistem pakar menggunakan metode forward chaining dalam mengidentifikasi penyakit kambing,” vol. 4, no. 4, pp. 7–10, 2022, doi: 10.37034/jidt.v4i4.216.
- [8] m. M. Dewi, I. 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.
- [9] 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.
- [10] y. Hendriyani, “perbandingan algoritma backpropagation dan learning vector quantization (lvq) dalam pengenalan pola bangun datar geometri,” vol. 20, no. 2, pp. 59–66, 2020.
- [11] m. Setya, a. Fauzi, b. Rahayudi, and c. Dewi, “perbandingan jaringan saraf tiruan lvq dengan backpropagation dalam deteksi dini penyakit jantung koroner,” vol. 3, no. 2, pp. 1952–1960, 2019.
- [12] i. G. Ayu, a. Diatri, and i. K. W. Adnyana, “analisis perbandingan metode lvq dan backpropagation dalam penentuan keaslian uang kertas rupiah berbasis parameter hsv,” vol. 5, no. April, pp. 73–83, 2019.
- [13] y. Aprizal, r. I. Zainal, u. B. Darma, j. S. Tiruan, and I. V. Quantization, “perbandingan metode backpropagation dan learning vector quantization (lvq) dalam menggali potensi mahasiswa baru di,” vol. 18, no. 2, pp. 294–301, 2019.
- [14] s. Zikrullah and h. S. Tambunan, “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.
- [15] i. I. Ridho, c. F. Ramadhani, and a. P. Windarto, “penerapan artificial neural network dengan metode backpropagation dalam memprediksi harga saham (kasus : pt . Bank bca , tbk),” vol. 8, pp. 295–303, 2023.
- [16] s. C. Mita and a. P. Windarto, “penerapan teknik neural network dalam memprediksi perkembangan impor kelompok industri tekstil dengan metode backpropagation,” vol. 3, no. 1, pp. 24–34, 2023.
- [17] d. Puspita et al., “metode jaringan saraf tiruan dalam memprediksi jumlah populasi itik manila berdasarkan provinsi di indonesia,” vol. 2, no. 2, pp. 51–65, 2022.
- [18] e. Kurniawan et al., “implementation of backpropagation method with nguyen widrow,” vol. 6, no. 1, pp. 49–54, 2019, doi: 10.25126/jtiik.20196904.
- [19] c. Astria, a. P. Windarto, and i. S. Damanik, “pemilihan model arsitektur terbaik dengan mengoptimasi learning rate pada neural network backpropagation,” vol. 9, no. 1, pp. 109–114, 2022, doi: 10.30865/jurikom.v9i1.3834.
- [20] b. Fachri, a. P. Windarto, and i. Parinduri, “penerapan backpropagation dan analisis sensitivitas pada prediksi indikator terpenting perusahaan listrik,” j. Edukasi dan penelit. Inform., vol. 5, no. 2, p. 202, 2019, doi: 10.26418/jp.v5i2.31650.
- [21] w. D. Utami and i. A. Wijaya, “optimasi model penugasan berdasarkan peramalan layanan backpropagation,” vol. 6, no. 1, pp. 41–47, 2023.
- [22] i. I. Ridho, a. Agung, g. Bagus, and a. P. Windarto, “optimasi fungsi pembelajaran jaringan saraf tiruan dalam meningkatkan akurasi pada prediksi ekspor kopi menurut negara tujuan utama,” vol. 4, no. 4, 2023, doi: 10.47065/bits.v4i4.3240.
- [23] a. F. Zuhri, a. P. Windarto, i. Parlina, m. Safii, s. R. Andani, and a. D. A. N. Pembahasan, “optimasi levenberg-marquardt backpropagation dalam mempercepat pelatihan backpropagation,” pp. 627–630, 2021.
- [24] s. M. Damanik, a. Perdana, w. Saputra, r. Dewi, and s. R. Andani, “optimasi data menggunakan teknik backpropagation dalam meningkatkan hasil nilai akurasi,” pp. 657–662, 2021.
- [25] a. Herawan, “pengembangan model jaringan syaraf tiruan untuk mendeteksi anomali satelit lapan- tubsat,” vol. 5, no. 2, pp. 230–239, 2019.
- [26] d. F. Auliasari, g. Febrianti, a. P. Windarto, and d. Hartama, “analisis model backpropagation dalam meramalkan tingkat penjualan saldo ‘ link aja ,”” vol. 2, no. 1, pp. 10–16, 2022.
- [27] r. S. Rosaamalia, tiara.santoso, “penerapan algoritma backpropagation dan optimasi conjugate gradient untuk klasifikasi hasil tes laboratorium,” vol. 11, pp. 506–511, 2023, doi: 10.14710/j.gauss.11.4.506-511.
- [28] b. Yanto, r. Hutagaol, and r. Rahman, “analisis optimasi algoritma backpropagation momentum dalam memprediksi jenis tingkat kejahatan di kecamatan tambusai utara budi,” vol. 1, pp. 47–60, 2022.
- [29] n. N. Amiroh and d. Avianto, “prediksi indeks pembangunan manusia di kabupaten wonosobo menggunakan algoritma backpropagation,” vol. 22, no. 2, pp. 388–399, 2023.