

Optimasi Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Penduduk Nasional

Misrianto^{1*}, Halimah Siregar²

¹ Prodi Teknik Industri, Universitas Balikpapan

Jl. Pupuk Raya, Gn. Bahagia, Kecamatan Balikpapan Selatan, Kota Balikpapan, Kalimantan Timur 76114

² Prodi Kesehatan Masyarakat, Universitas Islam Negeri Sumatera Utara

Jl. William Iskandar Ps. V, Medan Estate, Kec. Percut Sei Tuan, Kabupaten Deli Serdang, Sumatera Utara 20371

*Penulis Korespondensi: misrianto@uniba-bpn.ac.id

Abstract

Predictions or forecasting are important parameters in determining policy that will be implemented in the future. The higher population of a country, the more it will affect the balance of that country. This research aims to predict the national population using the Artificial Neural Network (ANN) approach. The sample for this research is population data for each province obtained from the National Central Statistics Agency (BPS). The data that is iterated from 2011 to 2022. The approach method uses backpropagation Artificial Neural Networks (ANN). The architectural model is determined with 2 hidden layers and 1 output, namely 5-20-10-1 with learning rate variations of 0.01, 0.02, and 0.03. ANN prediction results are able to predict the national population. The success of the three models shows that the ANN model with a Learning rate of 0.01 has the highest accuracy level of 96.9697, equivalent to 97%. This is proven by the model's success in predicting 32 out of 33 data samples with a time duration of 117 seconds. The prediction results showed that the highest population numbers were in three provinces, namely Central Java, West Java and East Java. Meanwhile, the lowest population is in West Papua province.

Keywords : BPS, JST, Learning Rate, Optimization.

Abstrak

Prediksi atau peramalan menjadi parameter penting dalam menentukan kebijakan yang dijalankan di masa mendatang. Semakin tinggi jumlah penduduk suatu Negara maka akan mempengaruhi keseimbangan Negara tersebut. Penelitian ini bertujuan untuk memprediksi jumlah penduduk Nasional menggunakan pendekatan Jaringan Saraf Tiruan (JST). Sampel penelitian ini adalah data jumlah penduduk setiap provinsi yang diperoleh dari Badan Pusat Statistik Nasional (BPS). Data yang di iterasi yaitu data dari tahun 2011 sampai tahun 2022. Metode pendekatan menggunakan Jaringan Saraf Tiruan (JST) back-propagation. Model arsitektur ditentukan dengan 2 hidden layers dan 1 output yaitu 5-20-10-1 dengan variasi Learning rate 0,01, 0,02, dan 0,03. Hasil prediksi JST mampu memprediksi jumlah penduduk Nasional. Keberhasilan dari ketiga model menunjukkan bahwa model JST dengan Learning rate 0,01 memiliki tingkat akurasi tertinggi sebesar 96,9697 setara 97%. Hal ini dibuktikan dengan keberhasilan model memprediksi 32 dari 33 sampel data dengan durasi waktu selama 117 detik. Hasil prediksi diperoleh jumlah penduduk tertinggi terdapat di tiga provinsi yaitu Jawa Tengah, Jawa Barat, dan Jawa Timur. Sedangkan jumlah penduduk terendah yaitu di provinsi Papua Barat.

Keywords: BPS, JST, Learning Rate, Optimasi.

Pendahuluan

Laju pertumbuhan jumlah signifikan terhadap pengambil penduduk memberikan pengaruh keputusan, pembuat kebijakan, bahkan

pelaksanaan program-program yang dikeluarkan oleh suatu Negara. Peningkatan jumlah angka kemiskinan menjadi salah satu faktor dari kekeliruan dalam melakukan prediksi/proyeksi jumlah penduduk (Nabawi 2020).

Terdapat beberapa metode yang dapat digunakan untuk menyelesaikan permasalahan tersebut diantaranya, penerapan metode *single and double moving average* (Kusuma, Ahsan, and Syahminan 2021), *regression linier* berganda (Kurniawan et al. 2022), *autoregression integrated moving average* (ARIMA) (Mardiyah et al. 2021), integrasi teknik *statistic Holt-Winter triple exponential smoothing pada fuzzy time series* (Wijanarko et al. 2023), dan *algorithm*.

Single and double moving average merupakan metode pendekatan dengan pola atau *trend* data *linier*. Hasil prediksi diperoleh tingkat akurasi MAPE (*mean absolute percentage error*) lebih kecil dari 10%. Hal ini menggambarkan bahwa masih terdapat penyimpangan prediksi sebesar < 10% dari total pengamatan (Kusuma et al. 2021). Multikolinieritas (*multicollinearities*) menjadi kekurangan dari metode *regression linier* berganda. Sehingga akan mempengaruhi hasil prediksi standar *error* dan *confidence level* semakin besar (Kurniawan et al. 2022). Sedangkan *Autoregression integrated moving average* (ARIMA) hanya dapat diaplikasikan pada pola data *linier* (Mardiyah et al. 2021) dan juga sama pada kombinasi teknik *statistic* dan *fuzzy* dengan data *time series* (Mardiyah et al. 2021).

Jaringan saraf tiruan (JST) merupakan metode pendekatan yang meniru sistem kerja jaringan saraf manusia. Metode ini sangat baik digunakan dalam menganalisa permasalahan prediksi/peramalan (*forecasting*) dan pengenalan pola.

Penerapan JST dalam mengenali pola gambar aksara batak dengan cara menerima/menyerap pola-pola aksara batak yang kemudian dikonversikan menjadi gambar *bipolar*. Setelah itu dilakukan pengodean (*encoding*) dengan

mengadopsi metode bilangan *biner* (0 dan 1). Hasil pengodean kemudian dikonversikan menjadi citra yang berwarna hitam atau putih. Susunan citra tersebut (hitam dan putih) akan menghasilkan gambar yang mirip dengan aksara batak yang menjadi target. Keberhasilan JST mengenali pola-pola aksara batak mencapai 97% (Sumantri et al. 2024).

Penerapan dalam peramalan atau prediksi curah hujan dan ketersediaan komoditas pangan. Prediksi curah hujan di Kota Denpasar menggunakan metode JST, dimana *hidden layer* diasumsikan mengikuti fungsi aktivasi *sigmoid biner* dan *output pure linear* (*purelin*). Asumsi lain pada inisiasi pembobotan awal dan pembobotan bias merujuk bilangan acak (*random number*) dan *learning rate* di *setting default* (0,01). Arsitektur JST terbaik diperoleh 12-50-1 dengan *hidden layer* sebesar 50 *neuron* dan iterasi sebanyak 11 *epoch*. Tingkat keberhasilan model mengacu pada nilai *mean square error* (MSE) sebesar 0.037 (Nailah et al. 2024).

Pada prediksi ketersediaan komoditas pangan Provinsi Riau menggunakan metode JST, dimana *hidden layer* diasumsikan menerapkan fungsi aktivasi *sigmoid biner* dan *output pure linear* (*purelin*). Pembobotan awal dan bias diasumsikan menggunakan bilangan acak (*random*) dan *learning rate* di *setting* 0.01, 0.02, dan 0.03. Arsitektur JST terbaik diperoleh 7-14-1 dengan nilai *epoch* 110 dan MSE 0.00334 (Edi and Cynthia 2017).

Penelitian prediksi atau peramalan jumlah penduduk di Provinsi Sumatera Utara dilakukan dalam upaya antisipasi peningkatan jumlah penduduk yang tidak dapat dikontrol. Sehingga berdampak *negative* terhadap pemerintahan Provinsi diantaranya ketidakstabilan sosial, meningkatnya kemiskinan, penurunan kualitas hidup, dan meningkatkan pengangguran. Arsitektur model diasumsikan 4-5-1, 4-10-1, dan 4-15-1. Keberhasilan dari ke-tiga model yaitu 4-15-1 dengan tingkat akurasi *mean square error* (MSE) sebesar 0,0000034 yang

membutuhkan durasi waktu selama 5 detik dan iterasi sebanyak 52 epoch (Napitupulu and Safii 2024).

Peneliti lain menerapkan JST untuk melakukan prediksi pelanggan listrik dengan membedakan pelanggannya. Kategorisasi pelanggan diantaranya rumah tangga, sosial, pemerintah, bisnis/usaha, dan industri. Arsitektur model yang digunakan sebanyak 5 dan input diasumsikan menerapkan fungsi aktivasi *tangent sigmoid* (tansig) dan *output log-sigmoid* (logsig). Asumsi lain yang digunakan adalah *learning rate* sebesar 0,1 dan iterasi sebanyak 2500000 epoch. Keberhasilan dari ke-lima model adalah arsitektur 4-45-1-1 dengan tingkat akurasi 80% (Haerani and Suhartini 2023).

Berdasarkan paparan diatas bahwa JST mampu menyelesaikan

permasalahan baik *linear* maupun *non-linear*, maka untuk optimalisasi prediksi jumlah penduduk nasional akan mempertimbangkan variasi *learning rate* dan menggunakan 2 *hidden layers*. Sehingga diharapkan *learning rate* optimal dalam memprediksi jumlah penduduk Nasional. Sedangkan tujuan penelitian ini untuk melakukan prediksi laju pertumbuhan jumlah penduduk Nasional.

Metodologi Penelitian

A. Data penelitian

Data penelitian menggunakan data sekunder yaitu Data Jumlah Penduduk Nasional Tahun 2011 – 2023. Data jumlah penduduk diperoleh dari BPS dengan jumlah data sebanyak 34 provinsi.

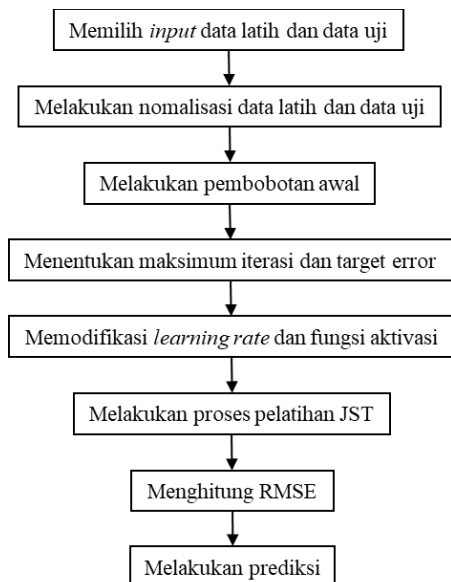
Tabel 1. Data Jumlah Penduduk Menurut Provinsi

Provinsi	Jumlah Penduduk menurut Provinsi (Ribu Jiwa)											
	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022
Aceh	4619	4715	4811	4907	5002	5096	5190	5281	5372	5275	5334	5408
Sumatera Utara	13221	13408	13590	13767	13938	14103	14262	14415	14563	14799	14936	15115
Sumatera Barat	4933	5000	5067	5132	5196	5260	5322	5382	5441	5534	5580	5641
Riau	5726	5879	6033	6188	6344	6501	6658	6815	6972	6394	6494	6614
Jambi	3168	3227	3286	3344	3402	3459	3515	3570	3625	3548	3585	3631
Sumatera Selatan	7599	7714	7829	7942	8052	8161	8267	8370	8471	8467	8551	8657
Bengkulu	1753	1784	1814	1845	1875	1905	1934	1963	1992	2011	2033	2060
Lampung	7736	7835	7932	8026	8117	8205	8290	8371	8448	9008	9082	9177
Kep. Bangka Belitung	1258	1287	1315	1344	1373	1402	1431	1460	1489	1456	1473	1495
Kepulauan Riau	1749	1805	1861	1917	1973	2028	2083	2137	2190	2065	2118	2180
DKI Jakarta	9752	9862	9970	10075	10178	10278	10374	10468	10558	10562	10610	10680
Jawa Barat	43939	44644	45341	46030	46710	47379	48038	48684	49317	48274	48782	49406
Jawa Tengah	32725	32999	33264	33523	33774	34019	34258	34491	34718	36516	36743	37032
DI Yogyakarta	3510	3553	3595	3637	3679	3721	3762	3803	3843	3669	3713	3762
Jawa Timur	37841	38107	38363	38610	38848	39075	39293	39501	39699	40666	40879	41150
Banten	10944	11199	11453	11705	11955	12203	12448	12690	12927	11905	12061	12252
Bali	3958	4007	4056	4105	4153	4200	4247	4292	4337	4317	4363	4415
Nusa Tenggara Barat	4582	4647	4711	4774	4836	4896	4956	5014	5070	5320	5390	5474
Nusa Tenggara Timur	4789	4871	4954	5037	5120	5204	5287	5372	5456	5326	5388	5466
Kalimantan Barat	4489	4566	4641	4716	4790	4862	4933	5002	5069	5414	5471	5541
Kalimantan Tengah	2275	2330	2385	2440	2495	2550	2605	2660	2715	2670	2702	2741
Kalimantan Selatan	3714	3785	3855	3923	3990	4056	4120	4183	4244	4074	4123	4182
Kalimantan Timur	3674	3772	3871	3970	3427	3501	3575	3649	3721	3766	3808	3860
Sulawesi Utara	2306	2334	2360	2387	2412	2437	2461	2484	2507	2622	2639	2660
Sulawesi Tengah	2693	2739	2786	2831	2877	2922	2966	3010	3054	2986	3022	3066
Sulawesi Selatan	8156	8250	8342	8432	8520	8606	8690	8772	8851	9074	9140	9226
Sulawesi Tenggara	2294	2346	2397	2448	2500	2551	2602	2654	2705	2625	2659	2702
Gorontalo	1063	1080	1098	1116	1133	1151	1168	1186	1203	1172	1181	1193
Sulawesi Barat	1188	1211	1234	1258	1282	1307	1331	1356	1380	1419	1437	1459
Maluku	1571	1600	1628	1657	1687	1716	1745	1774	1803	1849	1863	1882
Maluku Utara	1067	1091	1115	1139	1162	1186	1209	1233	1256	1283	1299	1319
Papua Barat	786	807	828	850	872	893	915	938	960	1134	1157	1183
Papua	2915	2974	3033	3091	3149	3207	3265	3323	3379	4304	4355	4419
Indonesia	241991	245425	248818	252165	255462	258705	261891	265015	268075	270204	272683	275774

Sumber: Data BPS

B. Tahapan penelitian

Adapun langkah-langkah penelitian dalam penerapan JST untuk memprediksi pertumbuhan jumlah penduduk nasional seperti pada gambar 1 dibawah.



Gambar 1. Diagram Alir Penelitian
 Sumber: (Nailah et al. 2024)

Hasil dan Pembahasan

Memilih input data latih dan data uji

Data dikelompokkan menjadi 2 bagian yaitu data latih dan data uji. Ketersediaan data dari BPS sebanyak 12 data, maka dari 12 data tersebut dibagi ke dalam 2 bagian yaitu sebanyak 6 data yang digunakan sebagai data latih dari tahun 2011 sampai 2016 dan sebanyak 6 data yang digunakan sebagai data uji dari tahun 2017 sampai 2022 (BPS 2023).

Normalisasi data latih dan data uji

Normalisasi data dilakukan untuk mencegah terjadinya keluaran (output) dari JST bernilai tak terbatas. Hal ini dipengaruhi oleh pemilihan fungsi aktivasi *sigmoid biner* yang nilainya dari *range* 0 sampai 1. Sehingga untuk menghindari keluaran (output) tak terbatas, maka masukan (input) diberikan perlakuan *treatment*. Salah satu metode normalisasi yang mampu menormalisasikan data tersebut yaitu *min-max method* (Chamidah, Wiharto, and

Salamah 2016). Metode ini atau disebut juga *min-max normalization* merupakan metode yang melakukan *rescale* data dari *range* awal ke dalam bentuk *range* yang lain. Perubahan bentuk data *rescale* ini dalam *range* 0 sampai 1.

$$s' = \frac{s - \min\{S_k\}}{\max\{S_k\} - \min\{S_k\}} \dots (1)$$

Dimana:

- s' : data hasil normalisasi
- s : data awal
- \max : nilai maksimum data
- \min : nilai minimum data
- $\{S_k\}$: dalam satu kolom

Tabel 2. Data Latih

2011	2012	2013	2014	2015	2016
0.089	0.089	0.089	0.090	0.090	0.090
0.288	0.287	0.287	0.286	0.285	0.284
0.096	0.096	0.095	0.095	0.094	0.094
0.114	0.116	0.117	0.118	0.119	0.121
0.055	0.055	0.055	0.055	0.055	0.055
0.158	0.158	0.157	0.157	0.157	0.156
0.022	0.022	0.022	0.022	0.022	0.022
0.161	0.160	0.160	0.159	0.158	0.157
0.011	0.011	0.011	0.011	0.011	0.011
0.022	0.023	0.023	0.024	0.024	0.024
0.208	0.207	0.205	0.204	0.203	0.202
1.000	1.000	1.000	1.000	1.000	1.000
0.740	0.734	0.729	0.723	0.718	0.713
0.063	0.063	0.062	0.062	0.061	0.061
0.859	0.851	0.843	0.836	0.828	0.821
0.235	0.237	0.239	0.240	0.242	0.243
0.074	0.073	0.073	0.072	0.072	0.071
0.088	0.088	0.087	0.087	0.086	0.086
0.093	0.093	0.093	0.093	0.093	0.093
0.086	0.086	0.086	0.086	0.085	0.085
0.035	0.035	0.035	0.035	0.035	0.036
0.068	0.068	0.068	0.068	0.068	0.068
0.067	0.068	0.068	0.069	0.056	0.056
0.035	0.035	0.034	0.034	0.034	0.033
0.044	0.044	0.044	0.044	0.044	0.044
0.171	0.170	0.169	0.168	0.167	0.166
0.035	0.035	0.035	0.035	0.036	0.036
0.006	0.006	0.006	0.006	0.006	0.006
0.009	0.009	0.009	0.009	0.009	0.009
0.018	0.018	0.018	0.018	0.018	0.018
0.007	0.006	0.006	0.006	0.006	0.006
0.000	0.000	0.000	0.000	0.000	0.000
0.049	0.049	0.050	0.050	0.050	0.050

Sumber: Hasil Normalisasi Data

Tabel 2 merupakan data latih JST yang sudah dilakukan *treatment* atau normalisasi. Data latih ini dibagi menjadi 2 bagian yaitu data latih dari tahun 2011 sampai 2015 digunakan sebagai data *input* ke JST. Sedangkan data tahun 2016 menjadi target yang akan dicapai oleh JST atau disebut juga sebagai *output* JST.

Tabel 3. Data Uji

2017	2018	2019	2020	2021	2022
0.091	0.091	0.091	0.088	0.088	0.088
0.283	0.282	0.281	0.290	0.289	0.289
0.094	0.093	0.093	0.093	0.093	0.092
0.122	0.123	0.124	0.112	0.112	0.113
0.055	0.055	0.055	0.051	0.051	0.051
0.156	0.156	0.155	0.156	0.155	0.155
0.022	0.021	0.021	0.019	0.018	0.018
0.157	0.156	0.155	0.167	0.166	0.166
0.011	0.011	0.011	0.007	0.007	0.006
0.025	0.025	0.025	0.020	0.020	0.021
0.201	0.200	0.198	0.200	0.198	0.197
1.000	1.000	1.000	1.000	1.000	1.000
0.708	0.703	0.698	0.751	0.747	0.743
0.060	0.060	0.060	0.054	0.054	0.053
0.814	0.808	0.801	0.839	0.834	0.829
0.245	0.246	0.247	0.228	0.229	0.230
0.071	0.070	0.070	0.068	0.067	0.067
0.086	0.085	0.085	0.089	0.089	0.089
0.093	0.093	0.093	0.089	0.089	0.089
0.085	0.085	0.085	0.091	0.091	0.090
0.036	0.036	0.036	0.033	0.032	0.032
0.068	0.068	0.068	0.062	0.062	0.062
0.056	0.057	0.057	0.056	0.056	0.056
0.033	0.032	0.032	0.032	0.031	0.031
0.044	0.043	0.043	0.039	0.039	0.039
0.165	0.164	0.163	0.168	0.168	0.167
0.036	0.036	0.036	0.032	0.032	0.031
0.005	0.005	0.005	0.001	0.001	0.000
0.009	0.009	0.009	0.006	0.006	0.006
0.018	0.018	0.017	0.015	0.015	0.014
0.006	0.006	0.006	0.003	0.003	0.003
0.000	0.000	0.000	0.000	0.000	0.000
0.050	0.050	0.050	0.067	0.067	0.067

Sumber: Hasil Normalisasi Data

Tabel 3 merupakan data uji JST yang sudah dilakukan *treatment* atau normalisasi. Data uji ini dibagi menjadi 2 bagian yaitu data uji dari tahun 2017 sampai 2021 digunakan sebagai data *input* ke JST. Sedangkan data tahun 2022 menjadi target yang akan dicapai oleh JST atau disebut juga sebagai *output* JST

Menentukan bobot awal

Proses penentuan bobot awal dapat menggunakan pendekatan nilai acak (*random*) dan Nguyen-widrow. Pada penelitian ini menggunakan nilai acak (*random*) dengan *interval* nilai dari 0 sampai 1. Penentuan merujuk pada pemilihan fungsi aktivasi yang digunakan. Penentuan bobot awal ini mempengaruhi hasil JST yaitu terjadinya *global minimize*, waktu *convergent*, dan proses pelatihan data sangat lama (Sawitri, Sumarjaya, and Tastrawati 2018).

Menentukan maksimum iterasi dan target error

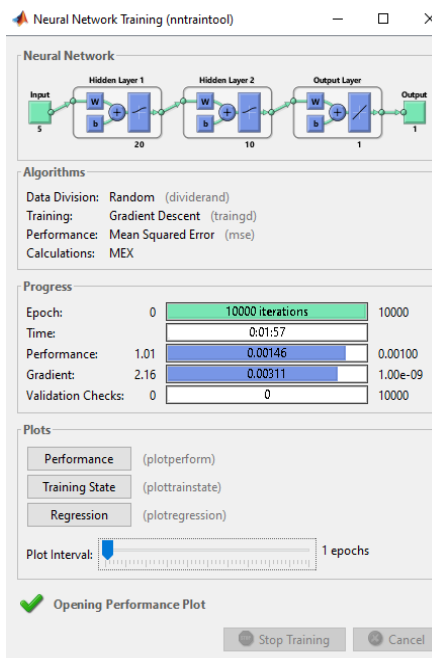
Proses penentuan maksimum iterasi pada penelitian ini menggunakan sebanyak 10000 iterasi dengan target error sebesar 0,001.

Memodifikasi learning rate dan fungsi aktivasi

Proses penentuan angka *learning rate* pada penelitian ini menggunakan 3 variasi yaitu 0,01, 0,02, dan 0,03. Sedangkan fungsi aktivasi menggunakan *sigmoid biner*, dimana fungsi ini digunakan sebagai *input* pada *hidden layer* 1 dan 2. Sedangkan untuk fungsi aktivasi *output* JST menggunakan *pure linear* (*purelin*). Fungsi aktivasi ini akan menghasilkan *output* berupa fungsi *linier* atau (Achmalia and Walid 2020).


Melakukan proses pelatihan

Proses pelatihan dan pengujian data menggunakan aplikasi MATLAB. Hasil model arsitektur yang digunakan untuk ketiga variasi *learning rate* yaitu 5-20-10-1. Pada model arsitektur 5 sebagai *input* data awal, 20 dan 10 merupakan *neuron* pada *hidden layer*, dan 1 menjadi *output* dari JST.



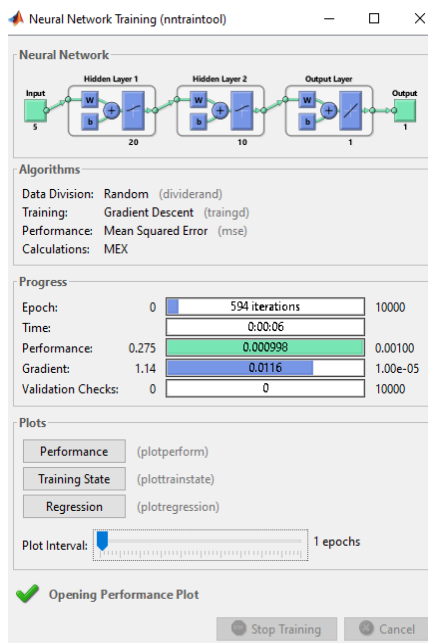
Gambar 2. Data Latih Learning Rate 0,01
 Sumber: Hasil Data Latih di MATLAB 2015a

Gambar 1 menunjukkan arsitektur JST dengan *learning rate* 0,01. Model ini menghasilkan tingkat akurasi sebesar 96,9697 setara 97% dengan *epoch* 1000 iterasi.



Gambar 2. Performance Data Latih *Learning Rate* 0,01
Sumber: Hasil Data Latih di MATLAB 2015a


Pada gambar 2 menggambarkan *performance* dari data latih dengan validasi terbaik sebesar 0,0027619 pada *epoch* 10000 iterasi.



Gambar 3. Data Latih *Learning Rate* 0,02
Sumber: Hasil Data Latih di MATLAB 2015a

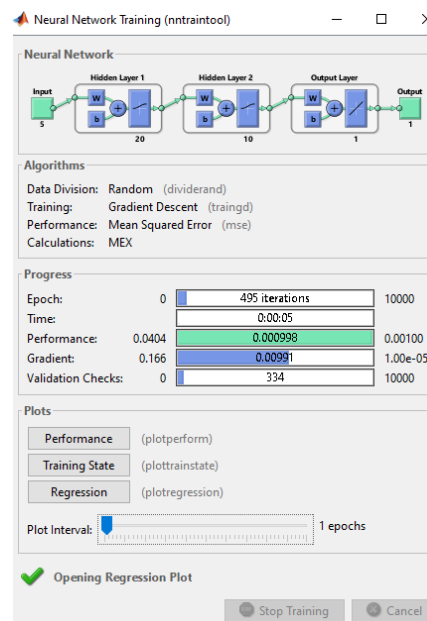
Gambar 3 menunjukkan arsitektur JST dengan *learning rate* 0,02. Model ini menghasilkan tingkat akurasi sebesar

93,9394 setara 94% dengan *epoch* 594 iterasi.




Gambar 4. Performance Data Latih *Learning Rate* 0,02
Sumber: Hasil Data Latih di MATLAB 2015a

Pada gambar 4 menggambarkan *performance* dari data latih dengan validasi terbaik sebesar 0,0060668 pada *epoch* 594 iterasi.



Gambar 5. Data Latih *Learning Rate* 0,03
Sumber: Hasil Data Latih di MATLAB 2015a

Gambar 5 menunjukkan arsitektur JST dengan *learning rate* 0,03. Model ini menghasilkan tingkat akurasi sebesar 90,9091 setara 91% dengan *epoch* 415 iterasi.



Gambar 6. Performance Data Latih Learning Rate 0,03

Sumber: Hasil Data Latih di MATLAB 2015a

Pada gambar 6 menggambarkan performance dari data latih dengan validasi terbaik sebesar 0,0026009 pada epoch 415 iterasi.

Hasil dari 3 data latih di atas terjadinya penurunan tingkat performance dari model secara perlahan dari 0,00276, 0,00607, dan 0,0026 hingga tahun 2024. Penurunan ini terjadi karena pengaruh learning rate di setiap data latih berbeda. Hal ini diperkuat dengan waktu yang dibutuhkan setiap data latih dalam melakukan iterasi yang berbeda-beda yaitu 117 detik, 6 detik, dan 5 detik.

Menghitung root mean square error (RMSE)

Hasil perhitungan root mean square error (RMSE) bertujuan untuk mengukur gap antara yang diprediksi dengan target yang ditentukan. Selain itu metode ini mampu memberikan informasi tingkat kesalahan pengukuran prediksi/peramalan model laju pertumbuhan penduduk Nasional. Hasil evaluasi RMSE dikatakan sesuai (valid), jika nilai MSE mendekati nol (Amira, Wiwik, and Raras 2014).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_t - f_t)^2}{n}} \dots (2)$$

Dimana:

- n : jumlah sampel
- x_t : nilai target
- f_t : nilai prediksi

Tabel 4. Data Latih Learning Rate 0,01

Target	Output	SSE	MSE	Validasi
0.090	0.077	0.013	0.000	1
0.284	0.196	0.088	0.008	1
0.094	0.079	0.015	0.000	1
0.121	0.093	0.027	0.001	1
0.055	0.060	-0.005	0.000	1
0.156	0.112	0.044	0.002	1
0.022	0.046	-0.024	0.001	1
0.157	0.113	0.044	0.002	1
0.011	0.041	-0.030	0.001	1
0.024	0.047	-0.023	0.001	1
0.202	0.139	0.063	0.004	1
1.000	0.822	0.178	0.032	0
0.713	0.839	-0.126	0.016	1
0.061	0.062	-0.002	0.000	1
0.821	0.749	0.072	0.005	1
0.243	0.165	0.078	0.006	1
0.071	0.068	0.004	0.000	1
0.086	0.075	0.012	0.000	1
0.093	0.079	0.014	0.000	1
0.085	0.075	0.011	0.000	1
0.036	0.051	-0.016	0.000	1
0.068	0.066	0.002	0.000	1
0.056	0.060	-0.004	0.000	1
0.033	0.050	-0.017	0.000	1
0.044	0.055	-0.012	0.000	1
0.166	0.118	0.048	0.002	1
0.036	0.052	-0.016	0.000	1
0.006	0.039	-0.034	0.001	1
0.009	0.040	-0.032	0.001	1
0.018	0.044	-0.026	0.001	1
0.006	0.039	-0.033	0.001	1
0.000	0.037	-0.037	0.001	1
0.050	0.058	-0.009	0.000	1
Total MSE			0.0869 0.0026	96.9697

Sumber: Hasil Perhitungan Manual RMSE

Tabel 4 menggambarkan perbedaan antara nilai target dan prediksi laju pertumbuhan penduduk Nasional. Nilai gap antara ke-duanya diperoleh sebesar 0,00263. Sedangkan kesesuaian atau kemiripan data (valid) antara ke-duanya < 0,1, maka hasil prediksi dikatakan valid. Nilai validasi data menunjukkan bahwa dari 32 data yang disimulasikan terdapat 1 data yang tidak memenuhi.

Tabel 5. Data Latih Learning Rate 0,02

Target	Output	SSE	MSE	Validasi
0.090	0.086	0.004	0.000	1
0.284	0.217	0.067	0.005	1
0.094	0.092	0.002	0.000	1
0.121	0.108	0.012	0.000	1
0.055	0.060	-0.005	0.000	1
0.156	0.145	0.011	0.000	1
0.022	0.040	-0.019	0.000	1
0.157	0.148	0.010	0.000	1
0.011	0.035	-0.024	0.001	1
0.024	0.040	-0.016	0.000	1
0.202	0.182	0.020	0.000	1
1.000	0.827	0.173	0.030	0

0.713	0.610	0.102	0.010	0
0.061	0.066	-0.005	0.000	1
0.821	0.815	0.007	0.000	1
0.243	0.194	0.049	0.002	1
0.071	0.074	-0.003	0.000	1
0.086	0.085	0.001	0.000	1
0.093	0.090	0.003	0.000	1
0.085	0.084	0.002	0.000	1
0.036	0.048	-0.012	0.000	1
0.068	0.070	-0.002	0.000	1
0.056	0.069	-0.013	0.000	1
0.033	0.048	-0.014	0.000	1
0.044	0.053	-0.010	0.000	1
0.166	0.156	0.010	0.000	1
0.036	0.048	-0.012	0.000	1
0.006	0.032	-0.027	0.001	1
0.009	0.034	-0.025	0.001	1
0.018	0.038	-0.021	0.000	1
0.006	0.033	-0.027	0.001	1
0.000	0.030	-0.030	0.001	1
0.050	0.057	-0.007	0.000	1
Total MSE			0.0539 0.0016	93.9394

Sumber: Hasil Perhitungan Manual RMSE

Tabel 5 menggambarkan perbedaan antara nilai target dan prediksi laju pertumbuhan penduduk Nasional. Nilai *gap* antara ke-duanya diperoleh sebesar 0,00163. Sedangkan kesesuaian atau kemiripan data (valid) antara ke-duanya < 0,1, maka hasil prediksi dikatakan valid. Nilai validasi data menunjukkan bahwa dari 31 data yang disimulasikan terdapat 2 data yang tidak memenuhi.

Tabel 6. Data Latih *Learning Rate* 0,03

Target	Output	SSE	MSE	Validasi
0.090	0.095	-0.005	0.000	1
0.284	0.319	-0.035	0.001	1
0.094	0.098	-0.004	0.000	1
0.121	0.098	0.022	0.001	1
0.055	0.092	-0.037	0.001	1
0.156	0.113	0.043	0.002	1
0.022	0.089	-0.068	0.005	1
0.157	0.115	0.042	0.002	1
0.011	0.089	-0.078	0.006	1
0.024	0.089	-0.064	0.004	1
0.202	0.151	0.050	0.003	1
1.000	0.770	0.230	0.053	0
0.713	0.523	0.190	0.036	0
0.061	0.093	-0.033	0.001	1
0.821	0.646	0.176	0.031	0
0.243	0.189	0.054	0.003	1
0.071	0.095	-0.024	0.001	1
0.086	0.097	-0.011	0.000	1
0.093	0.097	-0.004	0.000	1
0.085	0.096	-0.011	0.000	1
0.036	0.090	-0.054	0.003	1
0.068	0.093	-0.025	0.001	1
0.056	0.099	-0.043	0.002	1
0.033	0.090	-0.057	0.003	1
0.044	0.091	-0.047	0.002	1

0.044	0.091	-0.047	0.002	1
0.166	0.121	0.045	0.002	1
0.036	0.090	-0.054	0.003	1
0.006	0.089	-0.083	0.007	1
0.009	0.089	-0.080	0.006	1
0.018	0.089	-0.072	0.005	1
0.006	0.089	-0.083	0.007	1
0.000	0.089	-0.089	0.008	1
0.050	0.091	-0.041	0.002	1
Total MSE			0.1993 0.0060	90.9091

Sumber: Hasil Perhitungan Manual RMSE

Tabel 6 menggambarkan perbedaan antara nilai target dan prediksi laju pertumbuhan penduduk Nasional. Nilai *gap* antara ke-duanya diperoleh sebesar 0,00604. Sedangkan kesesuaian atau kemiripan data (valid) antara ke-duanya < 0,1, maka hasil prediksi dikatakan valid. Nilai validasi data menunjukkan bahwa dari 30 data yang disimulasikan terdapat 3 data yang tidak memenuhi.

Hasil dari 3 data latih di atas terjadinya penurunan tingkat akurasi secara perlahan dari 96,9697% menjadi 90,9091% di tahun 2024. Penurunan ini terjadi karena pengaruh *learning rate* di setiap data latih berbeda.

Tingkat keberhasilan dari data latih juga berbeda-beda dengan asumsi jika perbedaan nilai target dan output < 0,01, maka hasil prediksi dikatakan sesuai atau valid. Keberhasilan data latih dalam memprediksi jumlah penduduk pada data latih pertama sebanyak 32 sampel, data latih ke-dua 31 sampel, dan data latih ke-tiga 30 sampel.

Melakukan prediksi

Pada tahapan selanjutnya dilakukan prediksi jumlah penduduk dengan hasil *learning rate* terbaik yaitu 0,01.


Tabel 7. Hasil Prediksi Populasi

Provinsi	Jumlah Penduduk menurut Provinsi (Ribu Jiwa)			
	2021	2022	2023	2024
Aceh	5334	5408	4812	4151
Sumatera Utara	14936	15115	15005	15023
Sumatera Barat	5580	5641	4436	4189
Riau	6494	6614	4795	4377
Jambi	3585	3631	3912	3924
Sumatera Selatan	8551	8657	5632	4839
Bengkulu	2033	2060	3562	3754
Lampung	9082	9177	5683	4869
Kep. Bangka Belitung	1473	1495	3459	3705

Kep. Bangka Belitung	1473	1495	3459	3705
Kepulauan Riau	2118	2180	3571	3758
DKI Jakarta	10610	10680	7136	5764
Jawa Barat	48782	49406	43293	43289
Jawa Tengah	36743	37032	43259	43289
DI Yogyakarta	3713	3762	3991	3964
Jawa Timur	40879	41150	43287	43289
Banten	12061	12252	9019	7138
Bali	4363	4415	4134	4035
Nusa Tenggara Barat	5390	5474	4320	4129
Nusa Tenggara Timur	5388	5466	4412	4176
Kalimantan Barat	5471	5541	4302	4120
Kalimantan Tengah	2702	2741	3692	3817
Kalimantan Selatan	4123	4182	4069	4002
Kalimantan Timur	3808	3860	3979	3957
Sulawesi Utara	2639	2660	3684	3813
Sulawesi Tengah	3022	3066	3788	3863
Sulawesi Selatan	9140	9226	5923	5008
Sulawesi Tenggara	2659	2702	3698	3819
Gorontalo	1181	1193	3415	3684
Sulawesi Barat	1437	1459	3441	3696
Mahuku	1863	1882	3524	3736
Mahuku Utara	1299	1319	3421	3687
Papua Barat	1157	1183	3363	3659
Papua	4355	4419	3851	3894
Indonesia	271971	275048	271868	266418

Sumber: Hasil Perhitungan Prediksi

Berdasarkan tabel 7 hasil prediksi jumlah penduduk nasional cenderung mengalami penurunan pada setiap tahunnya. Sebaliknya setiap provinsi dari tahun 2021 sampai 2024 terjadinya fluktuatif pertumbuhan jumlah penduduk. Pertumbuhan jumlah penduduk di provinsi Aceh di tahun 2021 berjumlah 5334 jiwa dan menurun di tahun 2024 mejadi 4151 jiwa. Sedangkan pada provinsi Jambi mengalami peningkatan dari tahun 2024 sebesar 3924 jiwa dari tahun sebelumnya 2021 sebesar 3585 jiwa.



Gambar 7. Prediksi 2023-2024

Sumber: Hasil Perhitungan Prediksi

Berdasarkan gambar 7 plot hasil prediksi jumlah penduduk tahun 2023 sampai 2024. Pertumbuhan jumlah penduduk lebih tinggi terdapat pada provinsi Jawa Tengah, Jawa Timur, dan Jawa Barat.

Sedangkan pertumbuhan jumlah penduduk lebih rendah terdapat pada provinsi Papua Barat.

Kesimpulan

Berdasarkan hasil prediksi JST mampu melakukan prediksi atau peramalan Jumlah Penduduk Nasional. Prediksi atau peramalan ini menerapkan beberapa parameter yaitu model arsitektur 5-20-10-1, target *output* 0,001, variasi *learning rate* 0,01, 0,02, dan 0,03, dan total iterasi dari setiap data latih dan data uji sebanyak 1000.

Model arsitektur JST menggunakan 1 *input* dengan data *input* sebanyak 5 *neurons*, 2 *hidden layers* dengan *input* sebanyak 30 *neurons*, dan 1 *output*. Hasil ke-tiga data latih diperoleh prediksi atau peramalan terbaik menggunakan *learning rate* sebesar 0,01 dengan durasi waktu 01:57 dan iterasi 1000 *epoch*.

Tingkat keberhasilan dari ke-tiga data latih menunjukkan model JST dengan *learning rate* 0,01 memiliki akurasi terbaik yaitu sebesar 96,9697%. Keberhasilan ini dibuktikan model yang berhasil memprediksi sebanyak 32 dari 33 sampel.

Hasil prediksi atau peramalan jumlah penduduk nasional diperoleh jumlah prediksi tertinggi terdapat pada tiga provinsi yaitu Jawa Barat, Jawa Tengah, dan Jawa Timur. Sedangkan jumlah penduduk nasional terendah terdapat pada provinsi Papua Barat.

Daftar Pustaka

- Achmalia, Fany Aisyah, and Sugiman Walid. 2020. "Peramalan Penjualan Semen Menggunakan Backpropagation Neural Network Dan Recurrent Neural Network." *UNNES Journal of Mathematics* 9(1):6–21.
- Amira, Hutasuhut H., Anggraeni Wiwik, and Tyasnurita Raras. 2014. "Bahan Baku Plastik." *Jurnal Teknik POMITS* 3(2):169–74.
- BPS. 2023. "Penduduk, Laju Pertumbuhan Penduduk, Distribusi Persentase Penduduk, Kepadatan Penduduk, Rasio Jenis Kelamin Penduduk Menurut Provinsi, 2022." *Badan Pusat Statistik*

- Jawa Timur* 1–6.
- Chamidah, Nurul, Wiharto, and Umi Salamah. 2016. "Pengaruh Normalisasi Data Pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) Untuk Klasifikasi." *Jurnal Teknologi & Informasi ITSmart* 1(1):28. doi: 10.20961/its.v1i1.582.
- Edi, Ismanto, and Eka Pandu Cynthia. 2017. "Jaringan Syaraf Tiruan Algoritma Backpropagation Dalam Memprediksi Ketersediaan Komoditi Pangan Provinsi Riau." *Rabit: Jurnal Teknologi Dan Sistem Informasi Univrab* 2(2):196–209. doi: 10.36341/rabit.v2i2.152.
- Haerani, Rosita Putri Rahmi, and Erna Suhartini. 2023. "Analisis Kebutuhan Pengembangan Game Edukasi Online Untuk Meningkatkan Sustainability Literacy Pada Tema Perubahan Iklim." *Jurnal Ilmiah Pendidikan Dasar* 9(1):1792–1803.
- Kurniawan, Prawidana, Hanrian Rossa, Aditya Permana, Wahyu Adi Ramadan, Adhim Bagas Wisnu Aji, Syarif Hidayatulloh, Nur Iksan, and Ulfah Mediaty Arief. 2022. "Prediksi Jumlah Penduduk Jakarta Selatan Menggunakan Metode Regresi Linear Berganda." *Jurnal Sistem Dan Teknologi Informasi (JustIN)* 10(4):518. doi: 10.26418/justin.v10i4.48331.
- Kusuma, Febrian, Moh Ahsan, and Syahminan Syahminan. 2021. "Prediksi Jumlah Penduduk Miskin Indonesia Menggunakan Metode Single Moving Average Dan Double Moving Average." *Jurnal Informatika Dan Rekayasa Perangkat Lunak* 3(2):105. doi: 10.36499/jinrpl.v3i2.4594.
- Mardiyah, Ilmiatul, Wika Dianita Utami, Dian Candra Rini Novitasari, Moh. Hafiyusholeh, and Dewi Sulistiyawati. 2021. "Analisis Prediksi Jumlah Penduduk Di Kota Pasuruan Menggunakan Metode Arima." *BAREKENG: Jurnal Ilmu Matematika Dan Terapan* 15(3):525–34. doi: 10.30598/barekengvol15iss3pp525-534.
- Nabawi, Hafiz. 2020. "Pengaruh Jumlah Penduduk, Tingkat Pendidikan Dan PDRB Terhadap Kemiskinan Di Kota Malang." *OECOMICUS Journal of Economics* 4(2):104–17. doi: 10.15642/oje.2020.4.2.104-117.
- Nailah, Fadia, Dwi Ina Larasati, Siswanto Siswanto, and Anisa Kalondeng. 2024. "Optimasi Metode Jaringan Saraf Tiruan Backpropagation Untuk Peramalan Curah Hujan Bulanan Di Kota Denpasar." *MATHunesa: Jurnal Ilmiah Matematika* 12(1):134–40. doi: 10.26740/mathunesa.v12n1.p134-140.
- Napitipulu, Pretty Natalia, and M. Safii. 2024. "Penerapan Algoritma Backpropagation Dalam Prediksi Jumlah Penduduk Di Provinsi Sumatera Utara 1." 4:4–15.
- Sawitri, Made Nita Dwi, I. Wayan Sumarjaya, and Ni Ketut Tari Tastrawati. 2018. "Peramalan Menggunakan Metode Backpropagation Neural Network." *E-Jurnal Matematika* 7(3):264. doi: 10.24843/mtk.2018.v07.i03.p213.
- Sumantri, Wahyu Ekoliyono, Yasir Ammar Nasution, Suyono, and Rika Rosnelly. 2024. "Pengenalan Pola Aksara Batak Menggunakan Backpropagation Recognition of Batak Script Patterns Using Backpropagation." *Jurnal SISFOTENIKA* 14(1):57–67.
- Wijanarko, Toni, Adi Putra, M. Zakki Abdillah, Universitas Nasional Karangturi, Penulis Korespondensi, and Triple Exponential Smoothing. 2023. "Model Hybrid Untuk Prediksi Jumlah Penduduk Yang Hidup a Hybrid Model for the Prediction of the Number of Populations." *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)* 10(6):1253–64. doi: 10.25126/jtiik.2023107484.