

Analisa Metode Backpropagation Dalam Memprediksi Jumlah Perusahaan Konstruksi Berdasarkan Provinsi di Indonesia

Muhammad Kurniawansyah, Rafiqotul Husna, Raichan Septiono, Agus Perdana Windarto*, Putrama Alkhairi

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

Email: mkurniawansyah10@gmail.com, rafiqotulhusna61@gmail.com, raihanseptiono86@gmail.com,

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

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

Abstrak— Penelitian ini bertujuan untuk menganalisis jumlah perusahaan konstruksi di Indonesia dan memperoleh pemahaman tentang tren dan karakteristik industri konstruksi di negara tersebut. Dalam penelitian ini, data terkait jumlah perusahaan konstruksi dianalisis dengan menggunakan sumber-sumber yang tersedia seperti laporan statistik pemerintah, publikasi industri, dan sumber data sekunder lainnya. Data yang kami gunakan pada penelitian ini adalah data jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia dari tahun 2016-2021 yang diambil dari website badan pusat statistik (BPS) menggunakan metode jaringan syaraf tiruan (JST) backpropagation. Hasil analisis menunjukkan bahwa jumlah perusahaan konstruksi di Indonesia mengalami peningkatan yang signifikan dalam beberapa tahun terakhir. Penelitian ini diharapkan agar mendorong pertumbuhan ekonomi yang kuat dan meningkatnya investasi dalam infrastruktur dan sektor properti telah mendorong permintaan akan layanan konstruksi. Selain itu, kebijakan pemerintah yang mendukung sektor konstruksi, seperti program pembangunan infrastruktur dan regulasi yang memfasilitasi investasi asing, juga berkontribusi terhadap pertumbuhan jumlah perusahaan konstruksi. Selain tren pertumbuhan, penelitian ini juga mengidentifikasi beberapa karakteristik industri konstruksi di Indonesia. Industri ini didominasi oleh perusahaan kecil dan menengah yang beroperasi secara lokal, meskipun ada juga perusahaan besar yang terlibat dalam proyek-proyek skala besar. Persaingan dalam industri ini sangat ketat, dengan perusahaan-perusahaan yang berlomba-lomba untuk memenangkan kontrak konstruksi dan mengembangkan keunggulan kompetitif. Adapun model arsitektur yang kami gunakan dalam penelitian ini sebanyak 6 model arsitektur, yang mana nantinya akan di dapatkan satu model arsitektur terbaik. Adapun model arsitektur itu antara lain 5-11-1-1 dengan presentase akurasi 61.8%, 5-12-1-1 dengan presentase akurasi 70.6%, 5-14-1-1 dengan presentase akurasi 82.4%, 5-18-1-1 dengan presentase akurasi 64.7%, 5-20-1-1 dengan presentase akurasi 70.6%, 5-22-1-1 dengan presentase akurasi 73.5%. Sehingga diperoleh model arsitektur terbaik yaitu model 5-12-1-1 yang menghasilkan tingkat akurasi 82,4%. dengan Mean Square Error (MSE) sebesar 0,00099997 dengan rentan error antara 0,001-0,05. Hasil tersebut cukup baik dalam memprediksi jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia.

Kata Kunci: Jaringan Syaraf Tiruan (JST); Backpropagation; Mean Square Error (MSE); Jumlah Perusahaan Konstruksi; Prediksi

Abstract—This research aims to analyze the number of construction companies in Indonesia and gain an understanding of the trends and characteristics of the construction industry in that country. In this research, data related to the number of construction companies is analyzed using available sources such as government statistical reports, industry publications, and other secondary data sources. The data we use in this research is data on the number of construction companies by province in Indonesia from 2016-2021 which was taken from the website of the Central Statistics Agency (BPS) using the backpropagation artificial neural network (JST) method. The analysis results show that the number of construction companies in Indonesia has increased significantly in recent years. It is hoped that this research will encourage strong economic growth and increasing investment in the infrastructure and property sectors has driven demand for construction services. In addition, government policies that support the construction sector, such as infrastructure development programs and regulations that facilitate foreign investment, also contribute to the growth in the number of construction companies. Apart from growth trends, this research also identifies several characteristics of the construction industry in Indonesia. The industry is dominated by small and medium-sized companies operating locally, although there are also large companies involved in large-scale projects. Competition in this industry is fierce, with companies vying to win construction contracts and develop a competitive advantage. The architectural models that we use in this research are 6 architectural models, of which the best architectural model will be obtained. The architectural models include 5-11-1-1 with an accuracy percentage of 61.8%, 5-12-1-1 with an accuracy percentage of 70.6%, 5-14-1-1 with an accuracy percentage of 82.4%, 5-18-1-1 with an accuracy percentage of 64.7%, 5-20-1-1 with an accuracy percentage of 70.6%, 5-22-1-1 with an accuracy percentage of 73.5%. So the best architectural model is obtained, namely the 5-12-1-1 model which produces an accuracy rate of 82.4%. with a Mean Square Error (MSE) of 0.00099997 with an error prone of between 0.001-0.05. These results are quite good in predicting the number of construction companies based on provinces in Indonesia.

Keywords: Artificial Neural Network (ANN); Backpropagation; Mean Square Error (MSE); Number of Construction Companies; Prediction

1. PENDAHULUAN

Dalam era modern ini, industri konstruksi memiliki peran yang sangat penting dalam mendukung pertumbuhan ekonomi suatu negara. Di Indonesia, industri konstruksi menjadi salah satu sektor utama yang menyumbang kepada pembangunan infrastruktur dan menciptakan lapangan kerja[1], [2]. Namun, perencanaan dan pengelolaan industri konstruksi yang efisien memerlukan pemahaman yang mendalam tentang faktor-faktor yang mempengaruhi distribusi perusahaan konstruksi di berbagai provinsi. Salah satu pendekatan yang telah digunakan untuk memahami pola tersebut adalah metode backpropagation dalam konteks kecerdasan buatan [3].

Meskipun metode backpropagation telah diterapkan dalam berbagai bidang, aplikasinya dalam memprediksi jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia masih belum mendapatkan eksplorasi yang mendalam[4], [5]. Sebagai contoh, perbedaan karakteristik geografis, sosial, ekonomi, dan kebijakan regional di setiap provinsi dapat mempengaruhi distribusi perusahaan konstruksi. Oleh karena itu, penelitian ini sangat relevan untuk

dilakukan guna mengidentifikasi faktor-faktor yang dominan dalam mempengaruhi jumlah perusahaan konstruksi di setiap provinsi [6], [7].

Selain itu, pemahaman yang lebih baik tentang distribusi perusahaan konstruksi dapat memberikan wawasan yang berharga bagi pemerintah, pengembang, dan pelaku industri dalam merencanakan investasi dan pengembangan di sektor konstruksi. Dengan memahami pola distribusi ini, kebijakan publik yang lebih efektif dan efisien dapat dirumuskan, yang pada gilirannya akan mendukung pertumbuhan berkelanjutan sektor konstruksi dan ekonomi nasional secara keseluruhan [8], [9].

Pada penelitian terdahulu yang dilakukan oleh [5] dengan judul artikel “Effect of Gradient Descent With Momentum Backpropagation Training Function in Detecting Alphabet Letters” dengan metode Artificial Neural Network (ANN), algoritma tersebut dapat menghasilkan suatu sistem yang dapat mengenali pola karakter huruf tulisan tangan dengan baik yang dapat memudahkan manusia dalam mengenali pola dari huruf yang sulit dibaca karena berbagai faktor kesalahan yang dilihat manusia. Hasil proses pengujian menggunakan algoritma Backpropagation mencapai 100% dengan total 90 data latih. Hasil pengujian data pengujian mencapai 100% dari 90 data pengujian.

Sedangkan pada penelitian berikutnya yang dilakukan oleh [10] dengan judul artikel “Simulasi Metode Back Propagation Dalam Analisis Hasil Pengaruh Biji Karet Substitusi Agregat Kasar Terhadap Kuat Tekan Beton” Metode simulasi back propagation mampu memprediksi hasil pengujian dengan nilai error terkecil sebesar 3,5% dan error terbesar sebesar 47%. Metode backpropagation berhasil memprediksi hasil kuat tekan beton karena kesalahan prediksi kurang dari 50%. Hal ini dikarenakan data masukan yang dimasukkan sangat sedikit. Oleh karena itu, diperlukan penelitian lebih lanjut untuk mendapatkan hasil yang maksimal.

Namun, meskipun potensinya yang besar, penelitian tentang penggunaan metode backpropagation dalam konteks ini masih terbatas. Oleh karena itu, perlu dilakukan penelitian mendalam untuk mengisi kesenjangan pengetahuan ini [11], [12]. Penelitian ini tidak hanya akan memberikan kontribusi signifikan terhadap pemahaman kita tentang faktor-faktor yang mempengaruhi industri konstruksi di Indonesia, tetapi juga dapat membuka jalan bagi pengembangan model prediktif yang lebih akurat dan dapat diandalkan dalam merencanakan kebijakan dan strategi di masa depan [13], [14]. Dengan demikian, penelitian ini memiliki relevansi yang tinggi dalam mendukung pembangunan berkelanjutan dan pengelolaan yang efisien dalam sektor konstruksi Indonesia.

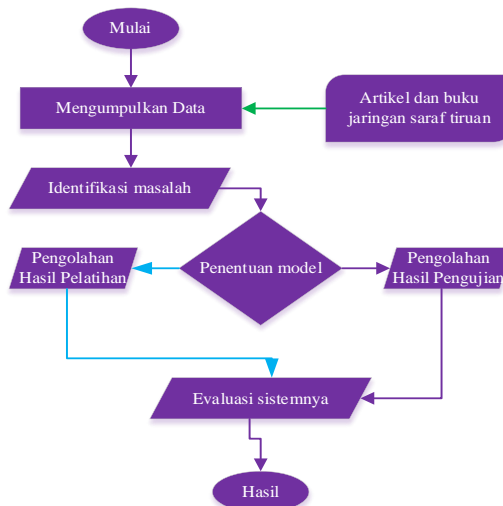
2. METODOLOGI PENELITIAN

Metodologi penelitian adalah serangkaian langkah sistematis yang digunakan untuk merancang, melaksanakan, dan menganalisis penelitian. Metodologi penelitian membantu peneliti dalam memperoleh data yang akurat, valid, dan reliabel serta memastikan bahwa kesimpulan yang dihasilkan dapat dipertanggungjawabkan. Metodologi penelitian juga melibatkan pemilihan sampel yang representatif, pemilihan instrument pengukuran yang valid serta mempertimbangkan etika penelitian.

2.1 Rancangan Penelitian

Dalam rangka mencapai tujuan yang ditetapkan, metodologi penelitian ini diterapkan dengan cara yang terstruktur untuk memastikan adanya alur kerja yang efektif. Hal ini bertujuan agar peneliti memiliki panduan yang jelas dalam melaksanakan penelitian, sehingga hasil yang di peroleh sesuai dengan yang diharapkan dan tidak menyimpang dari tujuan awal [2], [15].

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



Gambar 1. Rancangan Penelitian

Langkah-langkah rancangan penelitian untuk proyek Anda tentang analisis metode backpropagation dalam memprediksi jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia [16]:

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 [17]. Meskipun struktur jaringan syaraf ditentukan terlebih dahulu, pengolahan yang terjadi dalam jaringan tidak menghasilkan hipotesis secara langsung [18], [19]. 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 [20].

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_i dengan $j = 1, 2, 3, \dots, p$ menjumlahkan input yang berbobot

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

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 :

$$y_{ink} = V_{0k} + \sum_k^p = 1 Z_j W_{jk} \quad (3)$$

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

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

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

2.3 Data Penelitian

Adapun data yang kami gunakan dalam penelitian kali ini adalah jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia yang di ambil dari situs Badan Pusat Statistik (BPS) dari tahun 2016 sampai dengan tahun 2021. Pada tabel 1 merupakan data yang digunakna untuk penelitian ini.

Tabel 1. Data Jumlah Perusahaan Konstruksi

Provinsi	Jumlah Perusahaan Konstruksi					
	2016	2017	2018	2019	2020	2021
ACEH	5857	4546	4490	4913	5448	8614
SUMATERA UTARA	7329	7679	7476	7785	6956	10206
SUMATERA BARAT	4690	4973	5127	5337	5258	6365
RIAU	6534	7270	7736	8423	7798	7807
JAMBI	2953	3176	3146	3154	2958	3381
....
SULAWESI BARAT	1458	1377	1318	1245	1198	1396
MALUKU	2211	2260	2075	2236	1823	2347
MALUKU UTARA	2081	2497	2497	2506	2122	2238
PAPUA BARAT	1382	2824	3028	3702	3417	3453
PAPUA	3050	4927	5167	5830	5382	8149

Dalam algoritma backpropagation, akan digunakan berbagai jenis fungsi training, yaitu Gradient Descent Backpropagation (traingrp). Selain itu, fungsi training akan dikombinasikan dengan berbagai jenis fungsi aktivasi, antara lain sigmoid bipolar (tansig), dan sigmoid biner (logsig).

3. HASIL DAN PEMBAHASAN

3.1 Menentukan Data Training dan Data Testing

Berdasarkan penelitian yang terdokumentasikan dalam Tabel 3, data yang ada akan dibagi menjadi dua kelompok, yaitu data pelatihan (training) dan data pengujian (testing). Tidak ada aturan yang tetap untuk menentukan bagian mana yang menjadi data pelatihan dan bagian mana yang menjadi data pengujian. Namun, perlu dicatat bahwa data pelatihan dan target pelatihan tidak boleh sama dengan data pengujian dan target pengujian. Dalam penelitian ini, data pelatihan menggunakan data tahun 2016-2020 dengan target pelatihan tahun 2020. Sementara itu, data pengujian menggunakan data tahun 2017-2021 dengan target pengujian tahun 2021.

3.2 Normalisasi Data

Tujuan normalisasi data adalah agar keluaran dari jaringan sesuai dengan fungsi aktivasi sigmoid yang digunakan. Peneliti dalam penelitian ini menggunakan fungsi aktivasi sigmoid. Fungsi sigmoid memiliki sifat asimtotik, yang berarti nilainya tidak pernah mencapai 0 atau 1. Oleh karena itu, data subyek tersebut akan di transformasikan kedalam interval yang lebih kecil, yaitu antara 0,1 dan 0,8.

Adapun rumus normalisasi data adalah sebagai berikut :

$$x' = \frac{0,8(x-a)}{b-a} + 0,1$$

Keterangan :

x' = Hasil normalisasi

x = data yang akan di normalisasi

a = Data terkecil dari target

b = Data terbesar dari data set

Normalisasi data training dan testing menggunakan rumus sebagai berikut :

$$x' = \frac{0,8(5857-721)}{24596-721} + 0,1$$

Tabel 2. Normalisasi Data *Training*

Data	X ₁	X ₂	X ₃	X ₄	X ₅	Target
1	0.2721	0.2282	0.2263	0.2405	0.2584	0.2584
2	0.3214	0.3331	0.3263	0.3367	0.3089	0.3089
3	0.2330	0.2425	0.2574	0.2547	0.2520	0.2520
4	0.2948	0.3194	0.3351	0.3581	0.3371	0.3371
5	0.1748	0.1823	0.1813	0.1815	0.1750	0.1750
..
30	0.1247	0.1220	0.1200	0.1176	0.1160	0.1160
31	0.1499	0.1516	0.1454	0.1508	0.1369	0.1369
32	0.1456	0.1595	0.1595	0.1598	0.1469	0.1469
33	0.1221	0.1705	0.1773	0.1999	0.1903	0.1903
34	0.1780	0.2409	0.2490	0.2712	0.2562	0.2562

Tabel 3. Normalisasi Data *Testing*

Data	X ₁	X ₂	X ₃	X ₄	X ₅	Target
1	0.2282	0.2263	0.2405	0.2584	0.3645	0.3645
2	0.3331	0.3263	0.3367	0.3089	0.4178	0.4178
3	0.2425	0.2574	0.2547	0.2520	0.2891	0.2891
4	0.3194	0.3351	0.3581	0.3371	0.3374	0.3374
5	0.1823	0.1813	0.1815	0.1750	0.1891	0.1891
..
30	0.1220	0.1200	0.1176	0.1160	0.1226	0.1226
31	0.1516	0.1454	0.1508	0.1369	0.1545	0.1545
32	0.1595	0.1595	0.1598	0.1469	0.1508	0.1508
33	0.1705	0.1773	0.1999	0.1903	0.1915	0.1915
34	0.2409	0.2490	0.2712	0.2562	0.3489	0.3489

Maksud dari tabel 2 dan 3 dapat dilihat kriteria input data training dan data testing setelah proses normalisasi. Selanjutnya pada tabel 7 terdapat lima input data training dengan satu target, serta lima data testing dengan satu target input sebagai berikut:

Tabel 4. Kriteria Input Data *Training* dan Data *Testing*

Input Data Training			Input Data Testing		
No	Kriteria	Keterangan	No	Kriteria	Keterangan
1	X1	Data Tahun 2016	1	X1	Data Tahun 2017
2	X2	Data Tahun 2017	2	X2	Data Tahun 2018
3	X3	Data Tahun 2018	3	X3	Data Tahun 2019
4	X4	Data Tahun 2019	4	X4	Data Tahun 2020
5	X5	Data Tahun 2020	5	X5	Data Tahun 2021
6	Target	Data Tahun 2020	6	Target	Data Tahun 2021

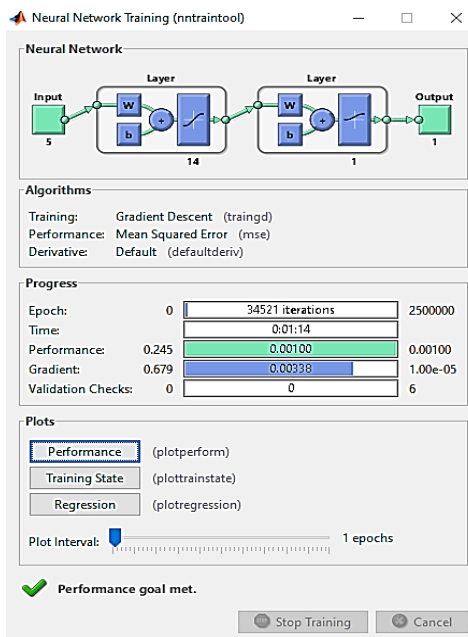
3.3 Penentuan Model Arsitektur

Dalam JST metode *backpropagation* sebenarnya tidak mempunyai aturan yang menetapkan adanya penggunaan model arsitektur, pemodelan dilakukan secara acak atau tidak menentu hingga di peroleh model terbaik dengan tingkat akurasi yang tinggi. Pada penelitian ini proses dilakukan dengan bantuan *software* matlab 2011a , pada prosesnya didapatkan lah 6 model arsitektur terbaik yang telah di latih dan di uji diantaranya 5-11-1-1, 5-12-1-1, 5-14-1-1, 5-18-1-1, 5-20-1-1, 5-22-1-1.

3.4 Hasil

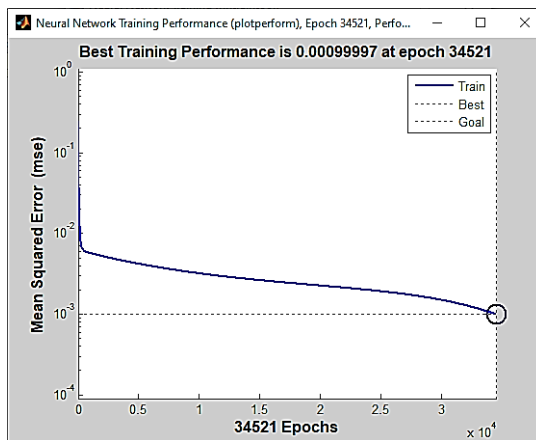
Penulis telah menetapkan 6 model arsitektur terbaik pada penelitian ini, antara lain 5-11-1-1 dengan presentase akurasi 61.8%, 5-12-1-1 dengan presentase akurasi 70.6%, 5-14-1-1 dengan presentase akurasi 82.4%, 5-18-1-1 dengan

presentase akurasi 64.7%, 5-20-1-1 dengan presentase akurasi 70.6%, 5-22-1-1 dengan presentase akurasi 73.5% . Maka ditetapkan Arsitektur 5-14-1-1 dengan presentase akurasi 82.4% sebagai model terbaik.



Gambar 2. Hasil Data Training 5-14-1-1

Pada gambar 2 diatas dapat kita lihat bahwa diperoleh hasil epoch yang terjadi sebanyak 34521 literations dengan waktu 01:14 detik.



Gambar 3. Hasil Epoch Training dengan Model Arsitektur 5-14-1-1

Dapat dilihat pada gambar 2 bahwa epoch yang telah dilakukan mendapatkan Mean Square Error (MSE) sebesar 0,00099997.

Tabel 5. Hasil Data Training Dan Testing Model Arsitektur Terbaik 5-14-1-1

Pola	Data Training			No	Data Testing			Hasil
	Output	Error	SEE		Output	Error	SEE	
1	0.2556	0.0028	0.00000784	1	0.303	0.0615	0.00378225	0
2	0.3473	-0.0384	0.00147456	2	0.4613	-0.0435	0.00189225	1
3	0.2629	-0.0109	0.00011881	3	0.2912	-0.0021	0.00000441	1
4	0.3358	0.0013	0.00000169	4	0.4019	-0.0645	0.00416025	0
5	0.1699	0.0051	0.00002601	5	0.1789	0.0102	0.00010404	1
6	0.1813	0.0136	0.00018496	6	0.2315	0.0317	0.00100489	1
7	0.1400	-0.0191	0.00036481	7	0.1421	-0.0161	0.00025921	1
8	0.1819	0.0304	0.00092416	8	0.1927	0.0284	0.00080656	1
9	0.1382	-0.0313	0.00097969	9	0.1388	-0.0309	0.00095481	1
10	0.1478	-0.0045	0.00002025	10	0.1549	0.0085	0.00007225	1
11	0.4056	-0.0043	0.00001849	11	0.588	-0.0261	0.00068121	1
12	0.4348	0.0129	0.00016641	12	0.6084	-0.1008	0.01016064	0

Data Training				Data Testing				Hasil
Pola	Output	Error	SEE	No	Output	Error	SEE	
13	0.4417	0.0179	0.00032041	13	0.6811	-0.0704	0.00495616	0
14	0.1427	-0.0068	0.00004624	14	0.1439	-0.0044	0.00001936	1
15	0.8693	-0.1424	0.02027776	15	0.9641	-0.0641	0.00410881	0
16	0.1669	0.0143	0.00020449	16	0.2583	0.0611	0.00373321	0
17	0.1478	-0.0095	0.00009025	17	0.1512	-0.0081	0.00006561	1
18	0.1713	0.0285	0.00081225	18	0.194	0.019	0.00036100	1
19	0.2752	-0.0026	0.00000676	19	0.3021	-0.0228	0.00051984	1
20	0.2773	-0.0186	0.00034596	20	0.3274	0.0065	0.00004225	1
21	0.1467	-0.0068	0.00004624	21	0.1473	0.0073	0.00005329	1
22	0.1975	0.0027	0.00000729	22	0.2205	0.0041	0.00001681	1
23	0.2404	-0.0148	0.00021904	23	0.3156	-0.0111	0.00012321	1
24	0.1407	-0.0209	0.00043681	24	0.1438	-0.0192	0.00036864	1
25	0.1519	-0.0092	0.00008464	25	0.1618	-0.0029	0.00000841	1
26	0.1775	0.0018	0.00000324	26	0.2002	0.0099	0.00009801	1
27	0.3836	0.0614	0.00376996	27	0.4182	0.0404	0.00163216	1
28	0.1785	0.0075	0.00005625	28	0.1895	0.007	0.00004900	1
29	0.1355	-0.0355	0.00126025	29	0.1361	-0.0308	0.00094864	1
30	0.1394	-0.0234	0.00054756	30	0.1400	-0.0174	0.00030276	1
31	0.1461	-0.0092	0.00008464	31	0.1554	-0.0009	0.00000081	1
32	0.1522	-0.0053	0.00002809	32	0.1568	-0.006	0.00003600	1
33	0.1643	0.026	0.00067600	33	0.1836	0.0079	0.00006241	1
34	0.2364	0.0198	0.00039204	34	0.3315	0.0174	0.00030276	1
Total			0.03400385	Total			0.04169192	82.4
MSE			0.001000113	MSE			0.00122623	

Keterangan :

Output : Diperoleh dari hasil perhitungan software matlab 2011a

Error : Diperoleh dari target output

SSE : Diperoleh dari $error^2$

Jumlah SSE : Total SSE dari pola 1-34

MSE : Diperoleh dari jumlah SSE/34 (jumlah pola data = 34)

Hasil : Diperoleh jika nilai error dalam data pengujian $\leq 0,05$ maka 1, jika tidak 0

Akurasi : Diperoleh dari jumlah hasil yang benar $((Pola/34)*100)$.

Analisa proses data latih dan data uji yang telah dilakukan, telah memiliki hasil pengolahan nya masing-masing, yang dapat dilihat pada tabel 6 berikut:

Tabel 6. Hasil Perbandingan Dari Masing Masing Model Terbaik

Model	5-11-1-1	5-12-1-1	5-14-1-1	5-18-1-1	5-20-1-1	5-22-1-1
MSE Pelatihan	0.000999541	0.000999856	0.001000113	0.001000112	0.000999889	0.000999859
MSE Pengujian	0.00672215	0.006784073	0.001226233	0.009493216	0.004594004	0.003383332
Epoch	13546	13672	34521	7383	10648	5618
Akurasi	61.8 %	70.6 %	82.4 %	64.7 %	70.6%	73.5 %

3.5 Pembahasan

Penelitian ini mengimplementasikan beberapa model jaringan saraf tiruan dengan variasi arsitektur (5-11-1-1, 5-12-1-1, 5-14-1-1, 5-18-1-1, 5-20-1-1, 5-22-1-1) untuk memprediksi jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia. Berikut adalah pembahasan hasil penelitian berdasarkan data yang diberikan:

1. Arsitektur Model:

Dalam penelitian ini, enam arsitektur model jaringan saraf tiruan telah dieksplorasi dengan variasi jumlah neuron dalam setiap lapisan. Hasil menunjukkan bahwa model dengan arsitektur 5-14-1-1 memberikan hasil terbaik dengan tingkat akurasi sebesar 82.4%. Hal ini menunjukkan bahwa konfigurasi 5 lapisan input, 14 lapisan tersembunyi pertama, 1 lapisan tersembunyi kedua, dan 1 lapisan output mampu menggambarkan pola data dengan sangat baik.

2. Mean Squared Error (MSE):

Nilai MSE pelatihan dan pengujian memberikan gambaran tentang seberapa baik model memahami data latih dan seberapa baik ia memprediksi data uji. Semakin rendah nilai MSE, semakin baik performa model. Dalam kasus ini, model dengan arsitektur 5-14-1-1 memiliki nilai MSE pelatihan sekitar 0.001, menunjukkan bahwa model ini

memiliki tingkat kesalahan yang rendah dalam memahami data latih. Namun, nilai MSE pengujian sekitar 0.001 hingga 0.01 menunjukkan bahwa model cenderung overfitting pada data uji pada beberapa arsitektur.

3. Epoch:

Epoch merujuk pada jumlah kali keseluruhan dataset digunakan selama pelatihan. Dalam penelitian ini, jumlah epoch bervariasi untuk setiap arsitektur model. Jumlah epoch yang tinggi pada beberapa model (misalnya, 34521 pada arsitektur 5-14-1-1) menunjukkan bahwa model tersebut memerlukan waktu yang lebih lama untuk konvergensi dan mendapatkan hasil yang optimal.

4. Akurasi:

Tingkat akurasi mencerminkan sejauh mana model berhasil memprediksi jumlah perusahaan konstruksi dengan benar. Model dengan arsitektur 5-14-1-1 menunjukkan akurasi tertinggi sebesar 82.4%, menandakan bahwa model ini dapat memprediksi jumlah perusahaan konstruksi berdasarkan provinsi dengan tingkat keberhasilan yang signifikan.

4. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa arsitektur model 5-14-1-1 adalah konfigurasi terbaik untuk memprediksi jumlah perusahaan konstruksi berdasarkan provinsi di Indonesia, dengan tingkat presentase akurasi sebanyak 82,4%. Meskipun beberapa model menunjukkan tingkat akurasi yang cukup tinggi, perlu diingat bahwa overfitting pada data uji merupakan masalah yang potensial, terutama pada beberapa arsitektur. Oleh karena itu, penelitian lanjutan dapat difokuskan pada teknik-teknik pencegahan overfitting dan peningkatan generalisasi model untuk memastikan hasil prediksi yang lebih konsisten dan handal dalam konteks aplikasi di dunia nyata.

REFERENCES

- [1] R. M. Riansah, R. W. Sembiring, And Z. Masruro, "Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Pelanggan Pt.Telkom Akses Area Sumbagut Menggunakan Metode Backpropagation," *Pros. Semin. Nas. Ris. Inf. Sci.*, Vol. 1, No. September, P. 804, 2019, Doi: 10.30645/Senaris.V1i0.87.
- [2] A. Wanto *Et Al.*, "Model Of Artificial Neural Networks In Predictions Of Corn Productivity In An Effort To Overcome Imports In Indonesia," *J. Phys. Conf. Ser.*, Vol. 1339, No. 1, 2019, Doi: 10.1088/1742-6596/1339/1/012057.
- [3] T. Sheng-Ping, H. Xu-Hong, Z. Nan, X. Wei-Hao, C. Yan-Yi, And Z. H. U. Cun-Xin, "Research On Two-Wheeled Vehicle Entry Ban System Based On Deep Learning Bt - Proceedings Of The 8th International Conference On Advanced Intelligent Systems And Informatics 2022," 2023, Pp. 224–233.
- [4] 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.
- [5] 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.
- [6] 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.
- [7] E. H. Houssein, M. M. Emam, And A. A. Ali, "An Optimized Deep Learning Architecture For Breast Cancer Diagnosis Based On Improved Marine Predators Algorithm," *Neural Comput. Appl.*, Vol. 34, No. 20, Pp. 18015–18033, 2022, Doi: 10.1007/S00521-022-07445-5.
- [8] N. Becherer, J. Pecarina, S. Nykl, And K. Hopkinson, "Improving Optimization Of Convolutional Neural Networks Through Parameter Fine-Tuning," *Neural Comput. Appl.*, Vol. 31, No. 8, Pp. 3469–3479, 2019, Doi: 10.1007/S00521-017-3285-0.
- [9] R. Poojary, "Comparative Study Of Model Optimization Techniques In Fine-Tuned Cnn Models," Pp. 22–25, 2019.
- [10] S. R. A. Ijurusan Fadhila Firdausal*, Raja Marpaung2, "Simulasi Metode Back Propagation Dalam Analisis Hasil Pengaruh Biji Karet Substitusi Agregat Kasar Terhadap Kuat Tekan Beton," Vol. 8, No. 2, 2020.
- [11] R. Poojary, R. Raina, And A. K. Mondal, "Effect Of Data-Augmentation On Fine-Tuned Cnn Model Performance," *Iaes Int. J. Artif. Intell.*, Vol. 10, No. 1, Pp. 84–92, 2021, Doi: 10.11591/ijai.V10.I1.Pp84-92.
- [12] A. Hedström *Et Al.*, "Quantus: An Explainable Ai Toolkit For Responsible Evaluation Of Neural Network Explanations," Vol. 24, Pp. 1–11, 2022, [Online]. Available: [Http://Arxiv.Org/Abs/2202.06861](http://Arxiv.Org/Abs/2202.06861)
- [13] S. Duan And J. C. Principe, "Labels, Information, And Computation: Efficient, Privacy-Preserving Learning Using Sufficient Labels," Vol. 24, Pp. 1–35, 2021, [Online]. Available: [Http://Arxiv.Org/Abs/2104.09015](http://Arxiv.Org/Abs/2104.09015)
- [14] M. I. Jordan, T. Lin, And M. Zampetakis, "First-Order Algorithms For Nonlinear Generalized Nash Equilibrium Problems," Vol. 24, Pp. 1–46, 2022, [Online]. Available: [Http://Arxiv.Org/Abs/2204.03132](http://Arxiv.Org/Abs/2204.03132)
- [15] H. Sibyan, W. Suharto, E. Suharto, M. A. Manuhutu, And A. P. Windarto, "Optimization Of Unsupervised Learning In Machine Learning," *J. Phys. Conf. Ser.*, Vol. 1783, No. 1, 2021, Doi: 10.1088/1742-6596/1783/1/012034.
- [16] 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.
- [17] A. G. Salman And Y. L. Prasetyo, "Dengan Metode Pembelajaran G Radient Descent Adaptive Learning Rate Untuk Pendugaan Curah Hujan Berdasarkan Peubah Enso Afan Galih Salman ; Yen Lina Prasetyo," Vol. 1, No. 2, Pp. 418–429.
- [18] 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.
- [19] Z. Xu, A. M. Dai, J. Kemp, And L. Metz, "Learning An Adaptive Learning Rate Schedule," *Arxiv*, Vol. 1909.09712, 2019.
- [20] 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.
- [21] 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.