

Analisis Penerapan Neural Network dalam Memprediksi Produksi Bijih Nikel di Indonesia

Muhammad Edya Rosadi^{1*}, Dian Agustini², Muthia Farida³, Dila Dwi Anjani⁴
^{1,2,3}Universitas Islam Kalimantan Muhammad Arsyad Al Banjari Banjarmasin,
Indonesia

⁴STIKOM Tunas Bangsa, Pematangsiantar, Indonesia
Email: edya@uniska-bjm.ac.id¹, dian.ftiuniskabjm@gmail.com²,
muthiafarida59@gmail.com³, diladwianjani22@gmail.com⁴

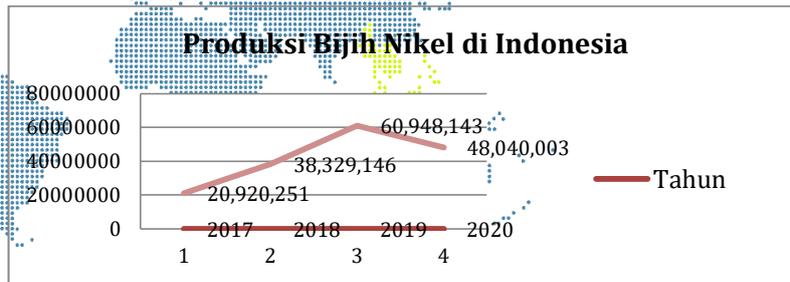
Abstract

Nickel ore is one of the exports from the mining subsector. About 72% of the world's nickel resources are found in lateritic nickel deposits, with approximately 15.8% of these deposits located in Indonesia. Nickel is currently one of the most discussed subjects in the world. As an essential component in the creation of batteries for electric vehicles, nickel is pushing changes in energy consumption. Managing nickel ore output in Indonesia is prudent in light of the government's efforts to increase national development, investment, employment, mining downstream, and export demands. To satisfy domestic and international demand, it is essential to examine nickel ore output. Consequently, an investigation is required to forecast nickel ore production. The dataset utilized is from the Central Bureau of Statistics's Publication of Non-Oil and Gas Mining Statistics for 2017-2020. This study employs a backpropagation network with an artificial neural network. The procedure is carried out by separating training data and testing data to choose the most accurate architectural model, which is subsequently utilized as a predictive model. The architectural models to be utilized with Matlab 6.1 are 2-45-1; 2-60-1; 2-75-80-1; 2-85-1; and 2-100-1. From a series of tests, it was determined that the best architectural model was 2-45-1 with a Mean Square Error of 0.00099549, epoch 335, and an accuracy of one hundred percent. This model was then utilized to create predictions.

Keywords: Artificial Neural Network, Backpropagation, Nickel Ore, Prediction, Architectural Model

1. Pendahuluan

Bijih nikel terbentuk dari endapan nikel laterit yang terjadi akibat pelapukan batuan ultramafik. Secara umum, nikel laterit biasa ditemukan di daerah tropis dengan iklim yang mendukung terjadinya pelapukan. Awalnya, nikel dianggap sebagai logam pengotor pada tembaga. Namun, kemajuan teknologi membuat para peneliti berhasil mengungkap manfaat nikel sebagai logam berharga. Sebagai bahan utama baterai isi ulang, pembuatan rangka utama otomotif, nikel menjadi pendorong perubahan dalam pemanfaatan energi. Upaya peningkatan pembangunan nasional, peningkatan investasi, pembukaan lapangan pekerjaan, hilirisasi pertambangan, serta kebutuhan ekspor, membuat pemerintah harus bijak dalam mengelola produksi bijih nikel di Indonesia. Jumlah produksi bijih nikel yang harus tersedia dapat menentukan permintaan bijih nikel yang dapat dilakukan. Untuk memenuhi permintaan kebutuhan domestik maupun mancanegara, perlu dilakukan analisis terhadap produksi bijih nikel. Oleh karena itu, diperlukan sebuah penelitian untuk memprediksi produksi bijih nikel di Indonesia. Berdasarkan Publikasi Statistik Pertambangan Non Minyak dan Gas Bumi di *website* Badan Pusat Statistik tahun 2017-2020 diperoleh data jumlah produksi bijih nikel sebagai berikut.



Gambar 1. Produksi Bijih Nikel di Indonesia

Dari grafik 1 di atas dapat dilihat dari tahun 2017 – 2019 jumlah produksi bijih nikel yang terus meningkat. Namun, pada tahun 2020 jumlah produksi mengalami penurunan sebesar 12.908.140 ton. Untuk menjaga produksi bijih nikel pada kebutuhan domestik, pemerintah diharapkan memiliki kebijakan dalam mengelola produksi bijih nikel serta menganalisis produksinya. Saat ini, telah banyak metode yang digunakan peneliti untuk melakukan prediksi. Kegiatan untuk memperkirakan apa yang akan terjadi pada masa yang datang, disebut peramalan (*forecasting*) [1]. Prediksi merupakan suatu proses penggunaan data masa lalu dari sebuah variabel atau kumpulan variabel untuk memperkirakan nilai di masa yang akan datang [2]. Dalam ilmu komputer, terdapat sebuah rumpun ilmu Kecerdasan Buatan yang dapat digunakan untuk meramal atau memprediksi yaitu jaringan saraf tiruan dengan algoritma *backpropagation* [3]. Jaringan seperti ini terdiri dari beberapa unit neuron yang terdiri atas *input layer*, *hidden layer* dan *output layer*. Di mana sinyal *input* merambat maju (ke lapisan *output*) lapis demi lapis [4]. Neural network memiliki kemampuan luar biasa untuk mengekstrak informasi dari data yang kompleks atau tidak tepat, mereka mampu memecahkan masalah yang tidak terstruktur dan sulit untuk didefinisikan, mereka dapat belajar dari pengalaman, mereka mampu mengekstrak informasi bahkan ketika tidak ada kepastian. mampu menggeneralisasi dan menarik dari pola data tertentu [5]. Jaringan saraf dikembangkan sebagai generalisasi model matematika kognisi manusia atau neurobiologi [6]. *Backpropagation* adalah algoritma pembelajaran untuk memperkecil tingkat *error* dengan cara menyesuaikan bobotnya berdasarkan perbedaan *output* dan target yang diinginkan [7].

Berdasarkan uraian di atas, penulis menggunakan jaringan saraf tiruan dengan algoritma *backpropagation* yang diterapkan dalam memprediksi produksi bijih nikel di Indonesia. Hasil yang diharapkan dapat menunjukkan nilai prediksi yang akurat, sehingga pihak terkait mampu mengambil kebijakan terhadap produksi bijih nikel serta menjaga nilai ekspor pada jenis barang tambang mineral tersebut.

2. Metodologi Penelitian

2.1. Kerangka Kerja Penelitian

Berdasarkan Gambar kerangka kerja diatas maka masing-masing langkah dapat diuraikan sebagai berikut :

a) Mengumpulkan Data

Penelitian ini memperoleh dataset dari Publikasi Statistik Pertambangan Non Minyak dan Gas Bumi di website resmi Badan Pusat Statistik periode 2017-2020.

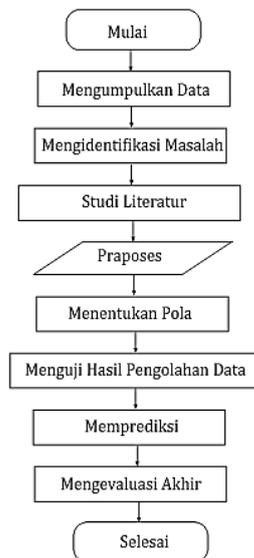
b) Mengidentifikasi Masalah

Pada tahap identifikasi masalah ini, dilakukan setelah semua data-data terpenuhi kemudian didapatkan dataset yang sesuai untuk dilakukan proses pada tahap konversi data yang didapat sesuai dengan bobot yang ditentukan.

c) Studi Literatur

Kajian literatur dilakukan untuk melengkapi informasi dasar dan teori yang digunakan dalam penelitian ini.

- d) Praproses
Dengan melakukan perubahan terhadap beberapa tipe data pada atribut dataset untuk memudahkan pemahaman tentang isi dataset dan membuat pilihan dengan memperhatikan konsistensi data, *missing value* dan redundansi dalam data. Tahap ini juga mencakup normalisasi data.
- e) Menentukan Pola
Menentukan pola arsitektur dan menentukan parameter yang akan digunakan. Data diolah dan ditransformasikan menjadi bilangan desimal antara 0 – 1.
- f) Menghuji Hasil Pengolahan Data
Setelah proses penentuan model selesai, maka dilakukan tahapan uji coba melalui *training* dan *testing* dengan *tools Matlab* untuk menentukan arsitektur terbaik sebagai acuan melakukan prediksi.
- g) Memprediksi
Melakukan prediksi dengan model arsitektur terbaik dan dengan proses denormalisasi data.
- h) Mengevaluasi Akhir
Memahami hasil yang didapatkan apakah sesuai yang diharapkan.
Adapun kerangka kerja yang digunakan dalam menyelesaikan penelitian ini adalah sebagai berikut.



Gambar 1. Kerangka Kerja Penelitian

2.2. Neural Network

Jaringan saraf tiruan merupakan suatu metode yang dapat menyelesaikan hubungan non-linear antara produksi dan berbagai faktor ekonomi, serta dapat menyesuaikan dengan perubahan yang akan terjadi [10]. JST dimaksudkan untuk menghasilkan model sistem komputasi yang sesuai dengan cara kerja jaringan saraf biologis [3]. Metode ini menggunakan elemen dasar komputer non linear yang disebut neuron yang diatur dalam jaringan yang saling berhubungan, seperti jaringan saraf manusia [11].

2.3. Proses Pembelajaran Jaringan

Paradigma/metode pembelajaran dan pelatihan JST adalah sebagai berikut [12] :

a) Pembelajaran Terawasi (*Supervised Learning*)

Dalam pembelajaran ini digunakan himpunan data *input*, data *output*nya diketahui. Selisih antara hasil aktual dengan data keluaran yang diinginkan digunakan untuk mengatur bobot JST agar JST dapat menghasilkan jawaban yang mendekati dengan jawaban benar yang diketahui JST.

b) Pembelajaran Tak Terawasi (*Unsupervised Learning*)

Dalam pembelajaran ini, JST mengatur diri sendiri untuk membentuk vektor *input* yang serupa tanpa menggunakan data pelatihan. Struktur berdasarkan data yang mendasari, atau korelasi antara pola data diperiksa. Paradigma pembelajaran ini mengatur pola ke dalam kategori berdasarkan korelasi yang ada.

c) Gabungan Pembelajaran Terawasi Dan Tak Terawasi (*Hybrid*)

Ini adalah kombinasi dari dua studi ini. Beberapa bobot ditentukan oleh pembelajaran terawasi dan pembelajaran sebagian tidak terawasi.

2.4. Backpropagation

Jaringan perambatan galat mundur (*backpropagation*) merupakan salah satu algoritma Jaringan Saraf Tiruan yang sering digunakan untuk menyelesaikan masalah-masalah yang rumit dan berkaitan dengan identifikasi input, prediksi, pengenalan pola, dan sebagainya [13]. Pengolahan data menggunakan algoritma *backpropagation* melalui beberapa tahapan yaitu tahap inisialisasi, tahap aktivasi, merubah bobot dari *input layer* ke *hidden layer*, merubah bobot dari *hidden layer* ke *output layer*, dan tahapan iterasi [14]. Setelah dilakukan inisialisasi, maka dilakukan iterasi dengan propagasi balik hingga kondisi yang ditetapkan terpenuhi [15]. Keunggulan utama dari sistem algoritma *backpropagation* adalah kemampuan “belajar” dari contoh yang diberikan. *Backpropagation* merupakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh *perceptron* dengan banyak layer lapisan untuk mengubah bobot-bobot yang ada pada lapisan tersembunyinya [16]. Pada tahapan penelitian *backpropagation* terdiri dari tahap pembacaan dataset, *preprocessing*, *cross validation*, *training* dan *testing*.

Kelebihan yang dimiliki *backpropagation* adalah mengatasi permasalahan pelatihan klasifikasi dengan skala data yang luas dan *robust* terhadap *missing data*. Hasil yang diperoleh adalah jumlah iterasi, waktu training dan akurasi [9]. *Backpropagation* merupakan algoritma yang sangat baik dalam proses klasifikasi karena kemampuannya dalam menyesuaikan kondisi jaringan dengan informasi yang dihasilkan oleh proses pembelajaran [8]. *Backpropagation* merupakan salah satu algoritma pelatihan *neural network* yang menggunakan metode *supervised learning*. Pada pelatihan *backpropagation* sama halnya seperti pelatihan pada jaringan saraf tiruan yang lain. Pada jaringan *feedforward*, kesalahan dihitung berdasarkan rata-rata kuadrat kesalahan (MSE) [17].

2.5. Prediksi

Prediksi merupakan suatu proses peramalan suatu kejadian dimasa mendatang dengan berdasarkan data variable dimasa sebelumnya [17]. Peramalan atau prediksi merupakan penelaahan tentang situasi yang menyelimuti lingkungan masa datang sebagai dasar pengambilan keputusan [18]. Tujuan dari prediksi adalah mendapatkan informasi apa yang akan terjadi dimasa datang dengan probabilitas kejadian terbesar [19]. Metode prediksi adalah metode yang mampu menganalisis satu atau lebih faktor yang diketahui mempengaruhi realisasi suatu peristiwa dalam tenggang waktu yang panjang antara terjadinya peristiwa di masa depan dan kebutuhan akan informasi. terjadi di masa lalu. Prakiraan adalah prediksi, antisipasi, atau penilaian/estimasi dari berbagai kemungkinan yang akan terjadi sebelum rencana yang lebih detail dapat dibuat [2].

3. Hasil Dan Pembahasan

3.1. Penetapan *Input* dan *Output*

a) Penetapan *Input*

Variabel produksi bijih nikel di Indonesia terdiri dari data produksi kayu hutan setiap tahunnya. Adapun variabel input jaringan saraf tiruan tentang produksi bijih nikel adalah sebagai berikut.

X1	=	Poduksi Kayu Lapis Tahun 2017
X2	=	Poduksi Kayu Lapis Tahun 2018

X3 = Produksi Kayu Lapis Tahun 2019
 X4 = Produksi Kayu Lapis Tahun 2020

b) Penetapan Output

Data *output* merupakan data prediksi produksi bijih nikel di Indonesia. Adapun variabel *output* jaringan saraf tiruan yakni Y sebagai prediksi produksi bijih nikel di Indonesia. Pada tahap ini, *output* yang diharapkan adalah terdeteksinya suatu nilai untuk penentuan pola arsitektur terbaik dari serangkaian penentuan pola yang dilakukan. Kategorisasi pola terbaik untuk memprediksi produksi bijih nikel di Indonesia adalah dengan menentukan tingkat *Error Minimum* dari target produksi bijih nikel. Pada penelitian ini, *error minimum* yang terbaik berkisar di antara **0.001-0.03**.

c) Pengolahan Data

Data *input* dibagi menjadi dua bagian, yakni data *training* (data produksi bijih nikel tahun 2017-2019) dan data *testing* (data produksi kayu lapis tahun 2018-2020). Kemudian ditransformasikan ke dalam bentuk *sigmoid biner* dengan rumus sebagai berikut.

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

Di mana :

x' = Hasil konversi data

x = Nilai yang akan dikonversi

a = Nilai minimum dari suatu kelompok data

b = Nilai maksimum dari suatu kelompok data

Sehingga diperoleh data sebagai berikut.

Tabel 1. Data Training

No	Tahun	Jumlah Produksi
1	2017	20,920,251
2	2018	38,329,146
3	2019	60,948,143

Berdasarkan Tabel 1, data dinormalisasikan dengan rumus (1) dan membuat pola rotasi dengan *input*=2 dan *output*=1 seperti Tabel 2 berikut.

Tabel 2. Normalisasi Data Training

	X1	X2	Y
Pola 1	0.1000	0.4479	0.9000
Pola 2	0.4479	0.9000	0.1000
Pola 3	0.9000	0.1000	0.4479

No	Tahun	Jumlah Produksi
2	2019	60,948,143
3	2020	48,040,003

Tabel 4. Normalisasi Data Testing

	X1	X2	Y
Pola 4	0.1000	0.9000	0.4435
Pola 5	0.9000	0.4435	0.1000
Pola 6	0.4435	0.1000	0.9000

Tabel 3. Data Testing

No	Tahun	Jumlah Produksi
1	2018	38,329,146

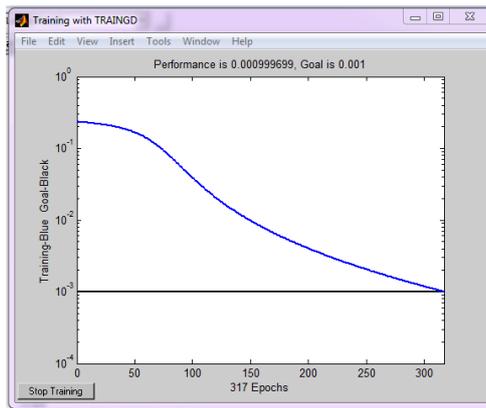
Berdasarkan Tabel 2 dan 4, normalisasi data produksi bijih nikel di Indonesia terdiri dari 6 pola yang dirotasikan. Di mana data *training* dan *testing* masing-masing terdiri dari 3 pola. Model arsitektur yang digunakan adalah 2-30-1; 2-60-1; 2-75-80-1; 2-85-1; 2-100-1. Dengan menggunakan *tools matlab*, parameter yang digunakan adalah sebagai berikut.

```
>>net=newff(minmax(P),[30,1],{'tansig','logsig'},'traingd')
>>net.LW{1,1}
>>net.b{1}
```

```
>>net.LW{2,1}
>>net.b{2}
>>net.trainparam.epochs=1500000
>>net.trainparam.LR=0.1
>>net.trainparam.goal=0.001
>>net.trainparam.show=100
>>net=train(net,P,T)
```

3.2. Arsitektur Training dan Testing 2-45-1

Berikut ini hasil training arsitektur 2-45-1 dengan *tools matlab* menghasilkan *epoch training* = 335 dan *Mean Square Error (MSE)* sebesar 0.0009954967.



Gambar 3. Hasil Epoch Training dengan Arsitektur 2-45-1

Berikut ini hasil data *training* dan *testing* untuk arsitektur 2-45-1 seperti pada Tabel 5 dan 6 berikut.

Tabel 5. Training Arsitektur 2-45-1

No	Real	Target	ANN 2-45-1		
			Output	Error	SSE
1	Pola 1	0.9000	0.8473	0.0527	0.0027772900
2	Pola 2	0.1000	0.1139	-0.0139	0.0001932100
3	Pola 3	0.4479	0.4425	0.0054	0.0000291600
Total					0.0029996600
MSE					0.0009998867

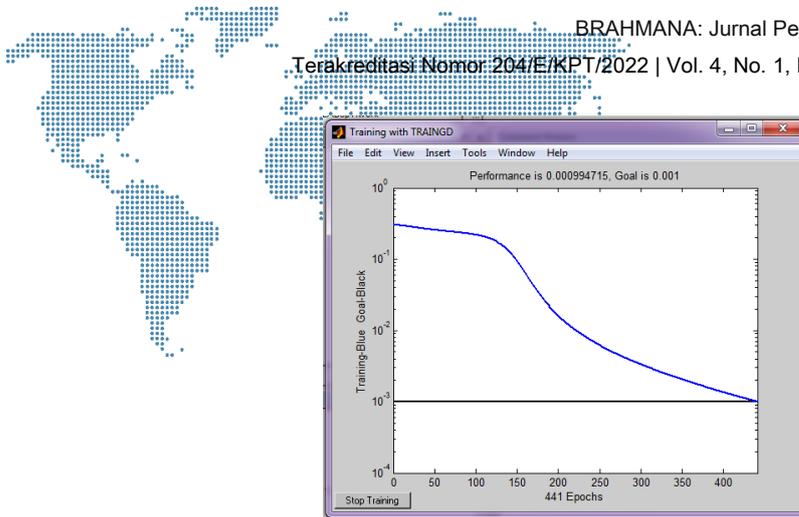
Tabel 6. Testing Arsitektur 2-45-1

No	Real	Target	ANN 2-30-1			
			Output	Error	SSE	Hasil
1	Pola 4	0.4435	0.4410	0.0025	0.0000062500	True
2	Pola 5	0.1000	0.0618	0.0382	0.0014592400	True
3	Pola 6	0.9000	0.8610	0.0390	0.0015210000	True
Total					0.0029864900	100%
MSE					0.0009954967	

Berdasarkan Tabel 6, tingkat akurasi kebenaran yang didapat sebesar 100%.

3.3. Arsitektur Training dan Testing 2-60-1

Berikut ini hasil training arsitektur 2-60-1 dengan *tools matlab* menghasilkan *epoch training* = 411 dan *Mean Square Error (MSE)* sebesar 0.0009946433.



Gambar 4. Hasil *Epoch Training* dengan Arsitektur 2-60-1

Berikut ini hasil data *training* dan *testing* untuk arsitektur 2-60-1 seperti pada Tabel 7 dan 8 berikut.

Tabel 7. Training Arsitektur 2-60-1

No	Real	Target	ANN 2-60-1		
			Output	Error	SSE
1	Pola 1	0.9000	0.8619	0.0381	0.0014516100
2	Pola 2	0.1000	0.1384	-0.0384	0.0014745600
3	Pola 3	0.4479	0.4555	-0.0076	0.0000577600
Total					0.0029839300
MSE					0.0009946433

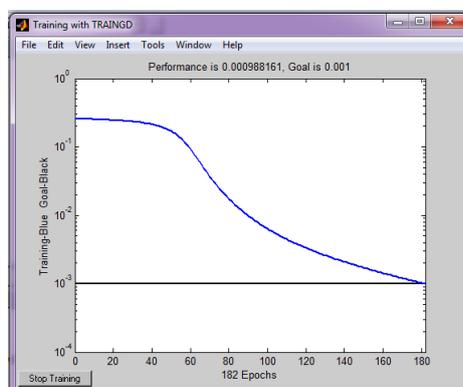
Tabel 8. Testing Arsitektur 2-60-1

No	Real	Target	ANN 2-60-1			
			Output	Error	SSE	Hasil
1	Pola 4	0.4435	0.4579	-0.0144	0.0002073600	True
2	Pola 5	0.1000	0.1493	-0.0493	0.0024304900	False
3	Pola 6	0.9000	0.9185	-0.0185	0.0003422500	True
Total					0.0029801000	67%
MSE					0.0009933667	

Berdasarkan Tabel 8, tingkat akurasi kebenaran yang didapat sebesar 67%.

3.4. Arsitektur Training dan Testing 2-75-80-1

Berikut ini hasil training arsitektur 2-75-80-1 dengan *tools matlab* menghasilkan *epoch training* = 227 dan *Mean Square Error* (MSE) sebesar 0.0009898500.



Gambar 5. Hasil *Epoch Training* dengan Arsitektur 2-75-80-1

Berikut ini hasil data *training* dan *testing* untuk arsitektur 2-75-80-1 seperti pada Tabel 9 dan 10 berikut.

Tabel 9. *Training* Arsitektur 2-75-80-1

No	Real	Target	ANN 2-75-80-1		
			Output	Error	SSE
1	Pola 1	0.9000	0.8695	0.0305	0.0009302500
2	Pola 2	0.1000	0.1451	-0.0451	0.0020340100
3	Pola 3	0.4479	0.4456	0.0023	0.0000052900
Total					0.0029695500
MSE					0.0009898500

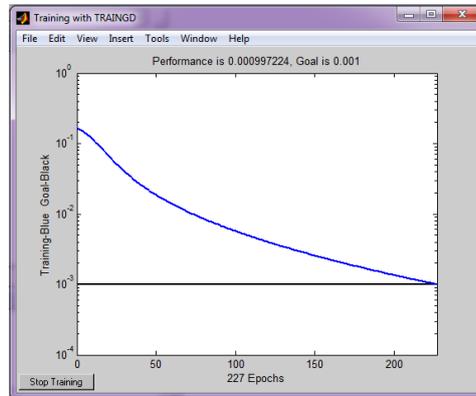
Tabel 10. *Testing* Arsitektur 2-75-80-1

No	Real	Target	ANN 2-75-80-1			
			Output	Error	SSE	Hasil
1	Pola 4	0.4435	0.4413	0.0022	0.0000048400	True
2	Pola 5	0.1000	0.1406	-0.0406	0.0016483600	False
3	Pola 6	0.9000	0.8638	0.0362	0.0013104400	True
Total					0.0029636400	67%
MSE					0.0009878800	

Berdasarkan Tabel 10, tingkat akurasi kebenaran yang didapat sebesar 67%.

3.5. Arsitektur Training dan Testing 2-85-1

Berikut ini hasil training arsitektur 2-85-1 dengan *tools matlab* menghasilkan *epoch training* = 227 dan *Mean Square Error* (MSE) sebesar 0.0009966767.



Gambar 6. Hasil *Epoch Training* dengan Arsitektur 2-85-1

Berikut ini hasil data *training* dan *testing* untuk arsitektur 2-85-1 seperti pada Tabel 11 dan 12 berikut.

Tabel 11. *Training* Arsitektur 2-85-1

No	Real	Target	ANN 2-85-1		
			Output	Error	SSE
1	Pola 1	0.9000	0.8609	0.0391	0.0015288100
2	Pola 2	0.1000	0.1381	-0.0381	0.0014516100
3	Pola 3	0.4479	0.4448	0.0031	0.0000096100
Total					0.0029900300
MSE					0.0009966767

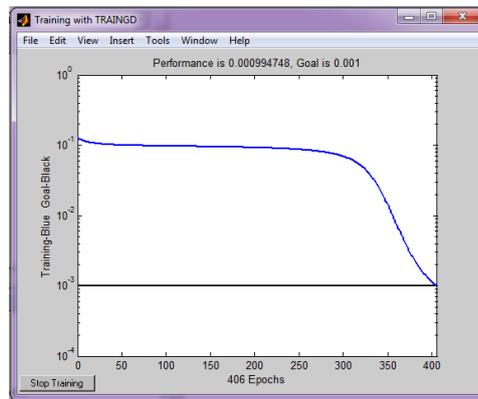
Tabel 12. Testing Arsitektur 2-85-1

No	Real	Target	ANN 2-85-1			Hasil
			Output	Error	SSE	
1	Pola 4	0.4435	0.4398	0.0037	0.0000136900	True
2	Pola 5	0.1000	0.1316	-0.0316	0.0009985600	True
3	Pola 6	0.9000	0.8556	0.0444	0.0019713600	False
Total					0.0029836100	67%
MSE					0.0009945367	

Berdasarkan Tabel 12, tingkat akurasi kebenaran yang didapat sebesar 67%.

3.6. Arsitektur Training dan Testing 2-100-1

Berikut ini hasil training arsitektur 2-75-80-1 dengan *tools matlab* menghasilkan *epoch training* = 406 dan *Mean Square Error* (MSE) sebesar 0.0009957800.



Gambar 7. Hasil *Epoch Training* dengan Arsitektur 2-100-1

Berikut ini hasil data *training* dan *testing* untuk arsitektur 2-100-1 seperti pada Tabel 13 dan 14 berikut.

Tabel 13. Training Arsitektur 2-100-1

No	Real	Target	ANN 2-100-1		
			Output	Error	SSE
1	Pola 1	0.9000	0.9335	-0.0335	0.0011222500
2	Pola 2	0.1000	0.1350	-0.0350	0.0012250000
3	Pola 3	0.4479	0.4732	-0.0253	0.0006400900
Total					0.0029873400
MSE					0.0009957800

Tabel 14. Testing Arsitektur 2-100-1

No	Real	Target	ANN 2-100-1			Hasil
			Output	Error	SSE	
1	Pola 4	0.4435	0.4499	-0.0064	0.0000409600	True
2	Pola 5	0.1000	0.1422	-0.0422	0.0017808400	False
3	Pola 6	0.9000	0.8660	0.0340	0.0011560000	True
Total					0.0029778000	67%
MSE					0.0009926000	

Berdasarkan Tabel 13, tingkat akurasi kebenaran yang didapat sebesar 67%.

3.7. Pemilihan Model Arsitektur Terbaik

Berdasarkan hasil *training* dan *testing* dengan menggunakan 5 model arsitektur pada algoritma *backpropagation* yakni: 2-45-1; 2-60-1; 20-75-80-1 dan 2-100-1, diperoleh model arsitektur 2-60-1 adalah yang terbaik dengan hasil akurasi prediksi 80%. Berikut ini hasil lengkap dari 4 model yang digunakan seperti yang ditunjukkan pada Tabel 15.

Tabel 15. Hasil Model Arsitektur

	2-45-1	2-60-1	2-75-80-1	2-85-1	2-100-1
MSE	0.0009954967	0.0009946433	0.0009898500	0.0009966767	0.0009957800
Epoch	335	441	182	227	406
Akurasi	100%	67%	67%	67%	67%

Dari hasil perancangan yang dibuat dihasilkan model terbaik untuk arsitektur 2-45-1. Model ini akan digunakan untuk memprediksi produksi bijih nikel dengan menentukan Y aktual dan Y prediksi dari *backpropagation*. Adapun rumus yang digunakan untuk memprediksi produksi bijih nikel adalah model arsitektur 2-45-1 adalah :

$$x = ((x' - 0,1)(x.\max - x.\min)/0,8) + x.\min \quad (2)$$

Keterangan :

- x' = Data Normalisasi
- x.max = Data Maksimal Asli
- x.min = Data Minimal Asli

3.8. Prediksi Produksi Bijih Nikel

Pada pengujian data untuk mendapatkan hasil prediksi yang diinginkan, digunakan model arsitektur 2-45-1 yang didapat dari langkah-langkah yang dilakukan dengan menggunakan *Matlab 6.1*. Hasil prakiraan jumlah produksi bijih nikel adalah sebagai berikut.

Tabel 16. Prediksi Produksi Bijih Nikel

Data Real	Target	Target Prediksi	Prediksi
48,040,003	0.9000	0.4478	48,162,754

4. Kesimpulan

Berdasarkan hasil dan pembahasan di atas, kesimpulan yang dapat diambil bahwa jaringan yang digunakan terdiri dari 3 layer yaitu input layer, hidden layer, dan output layer. Setelah dilakukan percobaan dalam proses pelatihan dan pengujian sistem dengan menggunakan software *Matlab 6.1*, Model arsitektur 2-45-1 adalah yang terbaik yang menghasilkan Epoch Training = 335 dan Mean Square Error (MSE) sebesar 0.0009954967. Dengan model arsitektur 2-45-1, prediksi produksi kayu hutan jenis kayu lapis di Indonesia menunjukkan akurasi 100%.

Daftar Pustaka

- [1] S. Alfarisi, "Sistem Prediksi Penjualan Gamis Toko QITAZ Menggunakan Metode Single Exponential Smoothing," *JABE (Journal Appl. Bus. Econ.)*, vol. 4, no. 1, p. 80, 2017, doi: 10.30998/jabe.v4i1.1908.
- [2] J. Andriano Frans, M. Orisa, and S. Adi Wibowo, "Prediksi Penjualan Kayu Lapis Di Cv Diato Wood Sejahtera Dengan Metode Trend Moment Berbasis Web," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 4, no. 2, pp. 183–190, 2020, doi: 10.36040/jati.v4i2.2719.
- [3] A. Revi, S. Solikhun, and M. Safii, "Jaringan Saraf Tiruan Dalam Memprediksi Jumlah Produksi Daging Sapi Berdasarkan Provinsi," *KOMIK (Konferensi Nas. Teknol. Inf. dan Komputer)*, vol. 2, no. 1, pp. 297–304, 2018, doi: 10.30865/komik.v2i1.941.
- [4] K. F. Irnanda, A. P. Windarto, and I. S. Damanik, "Optimasi Particle Swarm

- Optimization Pada Peningkatan Prediksi dengan Metode Backpropagation Menggunakan Software RapidMiner,” *J. Ris. Komput.*, vol. 9, no. 1, pp. 122–130, 2022. doi: 10.30865/jurikom.v9i1.3836.
- [5] Z. Fitri, “Analisis Error dan Epoch dengan Pengembangan Adaptive Learning Rate dan Parameter Momentum pada Metode Backpropagation,” vol. 3, no. 2, 2018.
- [6] P. Penjualan, S. Menggunakan, B. Neural, N. Dan, and R. Neural, “Backpropagation Neural Network Dan Recurrent Neural,” vol. 9, no. 1, pp. 6–21, 2020.
- [7] S. Wahyuni, “Jaringan Saraf Tiruan Memprediksi Kendaraan Masuk Pada Pengujian Kir Menggunakan Metode Backpropagation (Studi Kasus: Dinas Perhubungan Kota Binjai),” *Semin. Nas. Inform. ...*, 2021, [Online]. Available: <https://www.ejournal.pelitaindonesia.ac.id/ojs32/index.php/SENATIKA/article/view/1147>
- [8] M. Khairani, “Improvisasi Backpropagation menggunakan penerapan adaptive learning rate dan parallel training,” *TECHSI - J. Penelit. Tek. Inform.*, vol. 4, no. 1, pp. 157–172, 2014.
- [9] T. Brian, “Analisis Learning Rates Pada Algoritma Backpropagation Untuk Klasifikasi Penyakit Diabetes,” *EduTic - Sci. J. Informatics Educ.*, vol. 3, no. 1, pp. 21–27, 2017, doi: 10.21107/edutic.v3i1.2557.
- [10] F. Jefansa, “Penerapan Jaringan Saraf Tiruan dalam Meramalkan Produksi Kopi Berdasarkan Provinsi,” vol. 7, no. 1, pp. 1–7, 2022.
- [11] A. P. Windarto, M. R. Lubis, and S. Solikhun, “Implementasi JST pada Prediksi Total Laba Rugi Komprehensif Bank Umum dan Konvensional dengan Backpropagation,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 4, p. 411, 2018, doi: 10.25126/jtiik.201854767.
- [12] M. D. Wuryandari and I. Afrianto, “Perbandingan Metode Jaringan Saraf Tiruan Backpropagation Dan Learning Vector Quantization Pada Pengenalan Wajah,” *Komputa*, vol. 1, no. 1, pp. 45–51, 2012.
- [13] A. P. Windarto, “Implementasi Jst Dalam Menentukan Kelayakan Nasabah Pinjaman Kur Pada Bank Mandiri Mikro Serbelawan Dengan Metode Backpropogation,” *J-SAKTI (Jurnal Sains Komput. dan Inform.)*, vol. 1, no. 1, pp. 12–23, 2017.
- [14] S. H. Putri, Y. Yuhandri, and G. W. Nurcahyo, “Prediksi Pencapaian Target Peserta Keluarga Berencana Pasca Persalinan menggunakan Algoritma Backpropagation,” *J. Sistim Inf. dan Teknol.*, vol. 3, pp. 176–182, 2021, doi: 10.37034/jsisfotek.v3i3.62.
- [15] R. M. Firzattullah, “Menggunakan Sistem Pendukung Keputusan Penentuan Uang Kuliah Tunggal Universitas XYZ Menggunakan Algoritma Backpropagation,” *Petir*, vol. 14, no. 2, pp. 170–180, 2021, doi: 10.33322/petir.v14i2.996.
- [16] A. Zulhamsyah, S. Saifullah, and M. R. Lubis, “Penerapan Backpropagation Dalam Memprediksi Produksi Kelapa Sawit Unit Kebun Marjandi,” *KOMIK (Konferensi Nas. Teknol. Inf. dan Komputer)*, vol. 3, no. 1, pp. 779–787, 2019, doi: 10.30865/komik.v3i1.1693.
- [17] G. Guntoro, L. Costaner, and L. Lisnawita, “Prediksi Jumlah Kendaraan di Provinsi Riau Menggunakan Metode Backpropagation,” *Inform. Mulawarman J. Ilm. Ilmu Komput.*, vol. 14, no. 1, p. 50, 2019, doi: 10.30872/jim.v14i1.1745.
- [18] S. Irwanda, J. T. Hardinata, and I. S. Damanik, “Jaringan Saraf Tiruan Backpropogation dalam Memprediksi Jumlah Tilang di Kejaksaan Negeri Simalungun,” *Pros. Semin. Nas. Ris. Inf. Sci.*, vol. 1, no. September, p. 697, 2019, doi: 10.30645/senaris.v1i0.76.
- [19] A. Wanto and A. P. Windarto, “Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation,” *J. Penelit. Tek. Inform. Sink.*, vol. 2, no. 2, pp. 37–43, 2017, [Online]. Available: <https://zenodo.org/record/1009223#.Wd7norlTbhQ>