

# Analisis Performance Algoritma Powell-Beale untuk Prediksi Impor Aluminium

Gilang Rangga Junaidi <sup>1</sup>, Yogi Septian <sup>2</sup>, Anjar Wanto <sup>3\*</sup>, Agus Perdana Windarto <sup>4</sup>, Dedy Hartama <sup>5</sup>

<sup>1,2,3,4,5</sup> STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: <sup>1</sup>gilangranggaj@gmail.com, <sup>2</sup>yogiseptian0309@gmail.com, <sup>3\*</sup>anjarwanto@amiktunasbangsa.ac.id,

<sup>4</sup>agus.perdana@amiktunasbangsa.ac.id, <sup>5</sup>dedyhartama@amiktunasbangsa.ac.id

(\* : coressponding author)

## Abstrak

Alumunium merupakan salah satu Logam paling penting bagi dunia industri, akan tetapi sekarang ini alumunium mengalami kelangkaan seiring dengan kekurangan stok listrik yang membuat produsen membatasi produksinya. Oleh karena itu untuk mengatasi kelangkaan ini, pemerintah melakukan import alumunium. Import yang dilakukan secara terus menerus sedikit banyak nya akan mempengaruhi roda ekonomi di negara ini. Oleh sebab itu perlu dilakukan prediksi terhadap nilai import alumunium dimasa yang akan datang agar nantinya kebutuhan aluminium diindonesia stabil dan tidak terlalu berlebihan dalam melakukan import. Metode prediksi yang digunakan adalah algoritma Powell-beale yang merupakan salah satu metode Jaringan Saraf Tiruan yang sering digunakan untuk prediksi data. Makalah ini bukan membahas hasil prediksi, akan tetapi membahas kemampuan dari algoritma Powell-beale untuk melakukan prediksi berdasarkan dataset import Alumunium yang diperoleh dari Badan Pusat Statistik. Data penelitian yang digunakan adalah data import aluminium menurut negara asal utama dari tahun 2013-2020. Berdasarkan data ini akan dibentuk dan ditentukan model arsitektur jaringan, antara lain 3-5-1, 3-10-1, 3-15-1, 3-20-1 dan 3-25-1. Dari 5 model ini setelah dilakukan pelatihan dan pengujian diperoleh hasil bahwa model arsitektur terbaik adalah 3-5-1 dengan nilai MSE sebesar 0,02947426, paling rendah diantara 4 model yang lain. Sehingga dapat disimpulkan bahwa model tersebut dapat digunakan untuk melakukan prediksi import aluminium.

**Kata Kunci:** Performance, Import Aluminium, Powell-Beale, JST, Prediksi

## 1. PENDAHULUAN

Aluminium merupakan logam *non-ferrous* yang paling banyak digunakan didunia industri setelah besi dan baja. Seiring perkembangan waktu persediaan alumunium sering mengalami kelangkaan, sehingga pemerintah seringkali melakukan import dari negara luar untuk mencukupi kebutuhan terhadap alumunium. Impor yang dilakukan secara terus menerus sedikit banyak nya akan mempengaruhi roda ekonomi di negara ini [1], sehingga perlu dilakukan antisipasi untuk meminimalisir semakin meningkatnya ketergantungan import aluminium dari negara luar. Oleh sebab itu perlu dilakukan prediksi terhadap tingkat import alumunium dimasa yang akan datang agar nantinya kebutuhan aluminium diindonesia stabil dan tidak terlalu berlebihan dalam melakukan import. Metode prediksi yang diusulkan pada makalah adalah algoritma Powell-beale yang merupakan salah satu metode Jaringan Saraf Tiruan yang sering digunakan untuk prediksi data [2][3][4]. Akan tetapi pada makalah ini bukan membahas tentang hasil prediksi import alumunium di masa yang akan datang, tetapi membahas kemampuan dari algoritma Powell-Beale untuk melakukan prediksi berdasarkan dataset import Alumunium yang diperoleh dari Badan Pusat Statistik. Sebagaimana diketahui bahwa Powell-Beale merupakan salah satu algoritma optimasi dari backpropagation konvensional. Sehingga Pada Makalah ini akan menguji hal itu berdasarkan model-model arsitektur dan parameter yang telah ditentukan.

Mengetahui performance dari sebuah algoritma Jaringan Saraf tiruan sangat penting dilakukan untuk menghasilkan data peramalan yang akurat. Beberapa penelitian telah dilakukan, seperti penelitian Wanto dkk (2017) menggunakan algoritma backpropagation dan Fletcher-Reeves untuk menyelesaikan masalah prediksi indeks harga konsumen . Pada penelitian tersebut algoritma backpropagation unggul dalam hal akurasi prediksi dengan 75% berbanding 67%, tetapi dalam hal performance, MSE dan kecepatan, algoritma Fletcher-Reeves jauh lebih baik [5]. Keshtegar dkk (2019) membuat pearsitekturan nonlinear baru menggunakan modifikasi conjugate gradient Fletcher-Reeves untuk memperediksi ledakan udara yang disebabkan oleh induksi ledakan [6]. Tinambunan dkk (2020) menggunakan algoritma Polak-Ribiere untuk meningkatkan kinerja algoritma backpropagation standard dalam menyelesaikan masalah populasi penduduk. Pada penelitian ini algoritma Polak-Ribiere mampu meminimalkan iterasi dan penggunaan waktu [7].

Berdasarkan uraian terkait dari penelitian-penelitian sebelumnya, maka pada makalah ini akan menganalisis performance algoritma Powell-Beale untuk menyelesaikan masalah prediksi import alumunium menurut negara asal utama seperti Tiongkok, Australia hingga Jepang. Dataset ini hanya digunakan untuk bantuan pembuktian dan proses pengukuran kinerja dari algoritma tersebut. Tujuan penelitian ini untuk memperoleh optimasi keakuratan dan pengukuran Performance algoritma tersebut dalam pencarian hasil terbaik untuk menyelesaikan masalah prediksi import alumunium.

## 2. METODOLOGI PENELITIAN

### 2.1 Pengumpulan Data

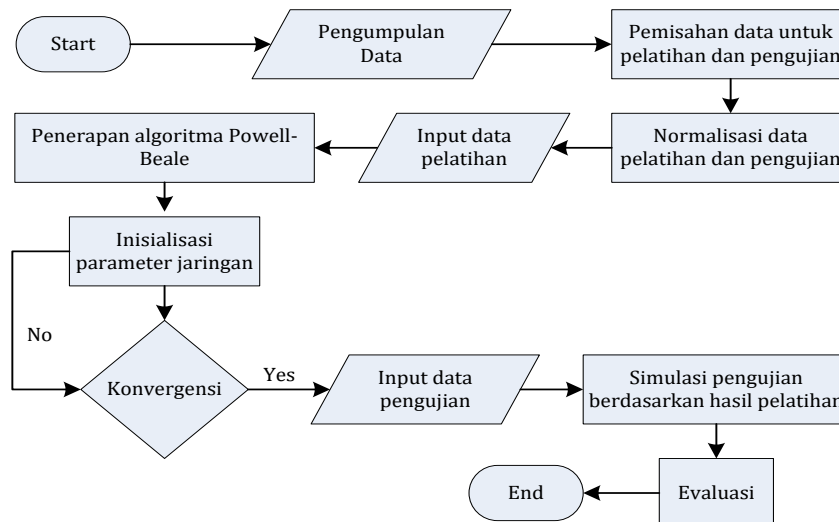
Pengumpulan data pada penelitian ini menggunakan metode kuantitatif, yakni data import aluminium menurut negara asal utama dari tahun 2013-2020 yang terdiri dari Tiongkok, Australia, Uni Emirat Arab, Malaysia, Amerika Serikat, Korea Selatan, Singapura, Qatar, Thailand dan Jepang. Data berasal dari website badan Pusat Statistik Indonesia.

**Tabel 1.** Impor Aluminium Menurut Negara Asal Utama (Kg)

Negara Asal	2013	2014	2015	2016	2017	2018	2019	2020
Tiongkok	141955,1	220461,1	164160,9	156560	233396,2	311145,6	255652,2	204843,5
Australia	121681,2	70508,4	51844,5	66260,6	70439,2	63297,4	43486,4	41117,8
Uni,Emirat,Arab	44436,5	49938,1	38973	55503,5	52322,9	51824,1	52119,6	28042,4
Malaysia,	42282,4	28258,3	35519,6	42835,6	44581,1	52002,6	49742,8	38255,4
Amerika,Serikat	30668,9	26550,9	30155,7	23886,4	37406,5	83287,9	105035,3	88325,9
Korea,Selatan	38189,8	33131,3	25573,9	32724,8	33420,3	29535,6	32988,2	25236,2
Singapura	12104,3	17056,1	22788,7	36418,3	29290,9	21014,6	18608,2	24640,3
Qatar	20046,4	17416	28157,4	29424,6	19847,4	16563,7	15150,9	9816,4
Thailand	14517,3	12560,1	14007,3	19351,9	21123,5	17210	15707,4	14965
Jepang	10374,7	8547,6	7872,5	7140	6402,8	7763,1	7062,4	6282,5

### 2.2 Alur Penelitian

Tahapan-tahapan yang dilakukan pada penelitian ini dapat dilihat pada gambar 1.



**Gambar 1.** Alur Penelitian

Berdasarkan gambar 1 dapat dijelaskan bahwa langkah pertama yang dilakukan dari tahapan penelitian adalah mengumpulkan dataset penelitian (Berdasarkan tabel 1). Langkah berikutnya memisahkan dataset penelitian menjadi 2 kelompok, yakni untuk data pelatihan dan pengujian. Tahapan berikutnya melakukan normalisasi data pelatihan dan pengujian dengan menggunakan rumus persamaan (1) [8]–[15].

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

Dimana :  $X'$  adalah hasil data yang sudah dinormalisasi, 0,8 dan 0,1 merupakan nilai default dari rumus normalisasi,  $X$  merupakan data yang akan dinormalisasi,  $b$  adalah nilai terendah dari dataset dan  $a$  merupakan nilai tertinggi dari dataset. Selanjutnya data pelatihan yang sudah dinormalisasi dimasukkan kedalam aplikasi Matlab 2011b untuk di proses, dilanjutkan dengan membuat jaringan saraf multi layer (input data pelatihan). Selanjutnya penerapan algoritma Powell-Beale. Pembuatan jaringan saraf multi layer ini menggunakan fungsi tansig dan logsig. Tahapan selanjutnya adalah dilakukan inisialisasi parameter jaringan berdasarkan fungsi pelatihan yang digunakan (traincgb). Kemudian memasukkan perintah untuk dilakukan proses pelatihan dan melihat hasil saat performance ditemukan. Apabila hasil pelatihan mencapai konvergensi, maka akan dilanjutkan memasukkan data pengujian yang sudah dinormalisasi. Tetapi jika hasil pelatihan belum mencapai konvergensi, maka kembali ke tahap inisialisasi parameter jaringan. Tahapan berikutnya dilanjutkan dengan simulasi data uji berdasarkan hasil pelatihan. Apabila semua sudah dilakukan, tahapan akhir adalah melakukan evaluasi untuk melihat model arsitektur terbaik berdasarkan Performance/MSE pengujian yang paling rendah (kecil).

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Pemisahan Data Pelatihan dan Pengujian

Langkah awal yang dilakukan setelah dataset penelitian tersedia adalah membagi data menjadi 2 bagian (data pelatihan dan data pengujian). Berdasarkan tabel 1, data latih menggunakan tahun 2013-2015 sebagai input dan tahun 2016 sebagai target (output). Sedangkan untuk data uji menggunakan tahun 2017-2019 sebagai input dan tahun 2020 sebagai target (output).

#### 3.2 Hasil Normalisasi

Data yang telah dibagi dua menjadi data latih dan data uji, selanjutnya dinormalisasi menggunakan rumus persamaan (1) yang sudah dibahas sebelumnya.

**Tabel 2.** Data Latih

Negara Asal	2013 (X1)	2014 (X2)	2015 (X3)	2016 (Target)
Tiongkok	0,4560	0,6620	0,5143	0,4943
Australia	0,4028	0,2685	0,2196	0,2574
Uni,Emirat,Arab	0,2001	0,2146	0,1858	0,2292
Malaysia	0,1945	0,1577	0,1767	0,1959
Amerika Serikat	0,1640	0,1532	0,1626	0,1462
Korea Selatan	0,1837	0,1705	0,1506	0,1694
Singapura	0,1153	0,1283	0,1433	0,1791
Qatar	0,1361	0,1292	0,1574	0,1607
Thailand	0,1216	0,1165	0,1203	0,1343
Jepang	0,1107	0,1059	0,1042	0,1023

**Tabel 3.** Data Uji

Negara Asal	2017 (X4)	2018 (X5)	2019 (X6)	2020 (Target)
Tiongkok	0,4560	0,6620	0,5143	0,4943
Australia	0,4028	0,2685	0,2196	0,2574
Uni,Emirat,Arab	0,2001	0,2146	0,1858	0,2292
Malaysia	0,1945	0,1577	0,1767	0,1959
Amerika Serikat	0,1640	0,1532	0,1626	0,1462
Korea Selatan	0,1837	0,1705	0,1506	0,1694
Singapura	0,1153	0,1283	0,1433	0,1791
Qatar	0,1361	0,1292	0,1574	0,1607
Thailand	0,1216	0,1165	0,1203	0,1343
Jepang	0,1107	0,1059	0,1042	0,1023

#### 3.3 Pelatihan dan Pengujian

Setelah tahapan normalisasi telah selesai dilaksanakan, selanjutnya adalah menentukan model arsitektur dan melatihnya menggunakan algoritma Powell-Beale dengan bantuan aplikasi Matlab 2011b. Model yang digunakan adalah 3-5-1 (3 input, 5 neuron hidden layer, 1 output), 3-10-1 (3 input, 10 neuron hidden layer, 1 output), 3-15-1 (3 input, 15 neuron hidden layer, 1 output), 3-20-1 (3 input, 20 neuron hidden layer, 1 output), 3-25-1 (3 input, 25 neuron hidden layer, 1 output). Sedangkan parameter algoritma Powell-Beale yang digunakan dapat dilihat pada gambar 2.

```

% Nilai parameter default Powell-Beale (traincgb)
net.trainParam.epochs = 1000;
net.trainParam.show = 25;
net.trainParam.showCommandLine = 0;
net.trainParam.showWindow = 1;
net.trainParam.goal = 0;
net.trainParam.time = inf;
net.trainParam.min_grad = 1e-6;
net.trainParam.max_fail = 5;
net.trainParam.searchFcn = 'srchcha'
    
```

**Gambar 2.** Parameter Powell-Beale

##### 3.3.1 Model 3-5-1

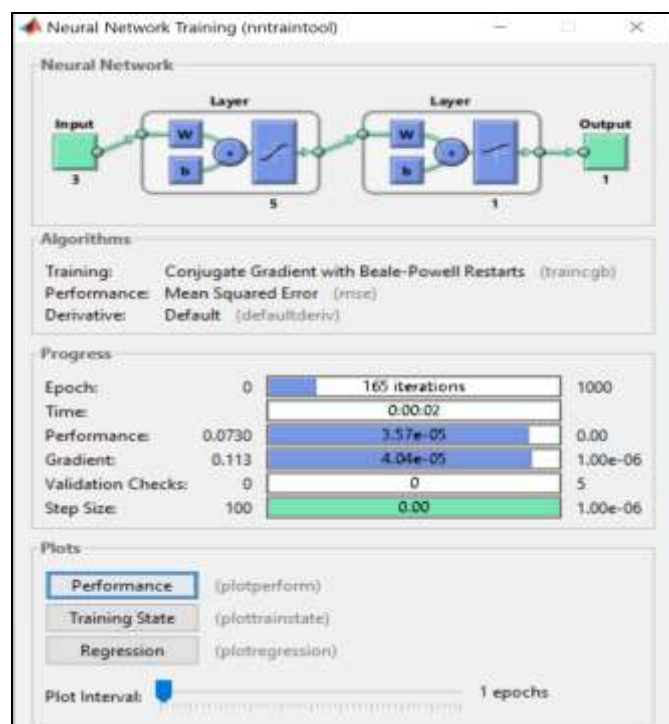
Hasil pelatihan dengan menggunakan model arsitektur 3-5-1 dapat dilihat pada gambar 3. Hasil pelatihan dengan menggunakan model ini menghasilkan epoch sebesar 165 iterasi. Untuk tabel pelatihan dan pengujianya dapat dilihat pada tabel 4 dan tabel 5.

**Tabel 4.** Hasil Pelatihan

Negara Asal	X1	X2	X3	Target	Actual	Error	Perf
Tiongkok	0,4560	0,6620	0,5143	0,4943	0,4943	0,0000	
Australia	0,4028	0,2685	0,2196	0,2574	0,2575	-0,0001	
Uni,Emirat,Arab	0,2001	0,2146	0,1858	0,2292	0,2281	0,0011	
Malaysia	0,1945	0,1577	0,1767	0,1959	0,1956	0,0003	
Amerika Serikat	0,1640	0,1532	0,1626	0,1462	0,1476	-0,0014	
Korea Selatan	0,1837	0,1705	0,1506	0,1694	0,1707	-0,0013	
Singapura	0,1153	0,1283	0,1433	0,1791	0,1790	0,0001	
Qatar	0,1361	0,1292	0,1574	0,1607	0,1624	-0,0017	
Thailand	0,1216	0,1165	0,1203	0,1343	0,1197	0,0146	
Jepang	0,1107	0,1059	0,1042	0,1023	0,1140	-0,0117	

**Tabel 5.** Hasil Pengujian

Negara Asal	X4	X5	X6	Target	Actual	Error	Perf
Tiongkok	0,6960	0,9000	0,7544	0,6210	0,5212	0,0998	0,02947426
Australia	0,2684	0,2496	0,1976	0,1914	0,2669	-0,0755	
Uni,Emirat,Arab	0,2208	0,2195	0,2203	0,1571	0,2663	-0,1092	
Malaysia	0,2005	0,2200	0,2140	0,1839	0,2472	-0,0633	
Amerika Serikat	0,1817	0,3021	0,3591	0,3153	0,8247	-0,5094	
Korea Selatan	0,1712	0,1610	0,1701	0,1497	0,1614	-0,0117	
Singapura	0,1604	0,1387	0,1323	0,1482	0,1078	0,0404	
Qatar	0,1356	0,1270	0,1233	0,1093	0,1024	0,0069	
Thailand	0,1389	0,1287	0,1247	0,1228	0,1014	0,0214	
Jepang	0,1003	0,1039	0,1020	0,1000	0,1371	-0,0371	



**Gambar 3.** Pelatihan dengan Matlab (3-5-1)

### 3.3.2 Model 3-10-1

Hasil pelatihan dengan menggunakan model arsitektur 3-10-1 dapat dilihat pada gambar 4. Hasil pelatihan dengan menggunakan model ini menghasilkan epoch sebesar 7 iterasi.

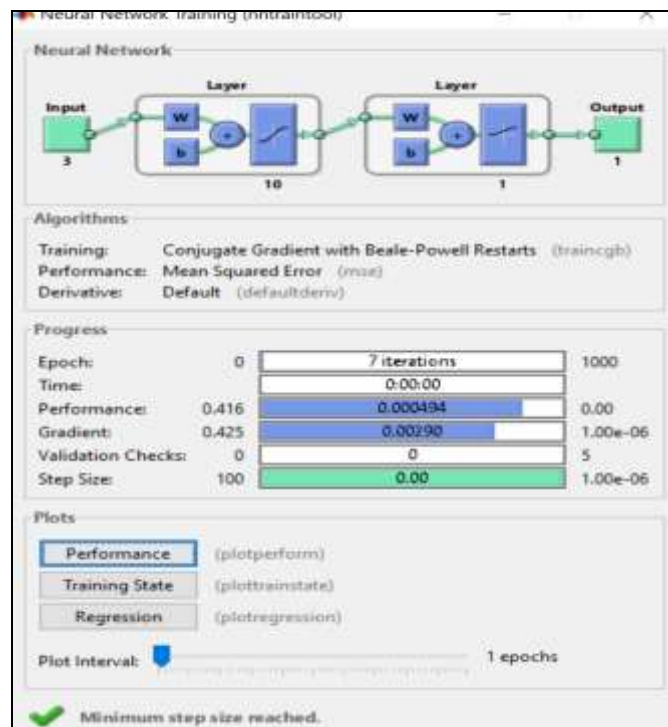
**Tabel 6.** Hasil Pelatihan

Negara Asal	X1	X2	X3	Target	Actual	Error	Perf
Tiongkok	0,4560	0,6620	0,5143	0,4943	0,5137	-0,0194	0,00049318
Australia	0,4028	0,2685	0,2196	0,2574	0,2524	0,0050	
Uni,Emirat,Arab	0,2001	0,2146	0,1858	0,2292	0,2516	-0,0224	
Malaysia	0,1945	0,1577	0,1767	0,1959	0,1543	0,0416	
Amerika Serikat	0,1640	0,1532	0,1626	0,1462	0,1458	0,0004	
Korea Selatan	0,1837	0,1705	0,1506	0,1694	0,1305	0,0389	
Singapura	0,1153	0,1283	0,1433	0,1791	0,1880	-0,0089	
Qatar	0,1361	0,1292	0,1574	0,1607	0,1682	-0,0075	
Thailand	0,1216	0,1165	0,1203	0,1343	0,1332	0,0011	
Jepang	0,1107	0,1059	0,1042	0,1023	0,1277	-0,0254	

**Tabel 7.** Hasil Pengujian

Negara Asal	X4	X5	X6	Target	Actual	Error	Perf
Tiongkok	0,6960	0,9000	0,7544	0,6210	0,3532	0,2678	0,04132080
Australia	0,2684	0,2496	0,1976	0,1914	0,4102	-0,2188	

Negara Asal	X4	X5	X6	Target	Actual	Error	Perf
Uni,Emirat,Arab	0,2208	0,2195	0,2203	0,1571	0,3920	-0,2349	
Malaysia	0,2005	0,2200	0,2140	0,1839	0,3342	-0,1503	
Amerika Serikat	0,1817	0,3021	0,3591	0,3153	0,7753	-0,4600	
Korea Selatan	0,1712	0,1610	0,1701	0,1497	0,1560	-0,0063	
Singapura	0,1604	0,1387	0,1323	0,1482	0,1042	0,0440	
Qatar	0,1356	0,1270	0,1233	0,1093	0,1177	-0,0084	
Thailand	0,1389	0,1287	0,1247	0,1228	0,1155	0,0073	
Jepang	0,1003	0,1039	0,1020	0,1000	0,1461	-0,0461	



**Gambar 4.** Pelatihan dengan Matlab (3-10-1)

### 3.3.3 Model 3-15-1

Hasil pelatihan dengan menggunakan model arsitektur 3-15-1 dapat dilihat pada gambar 5. Hasil pelatihan dengan menggunakan model ini menghasilkan epoch sebesar 254 iterasi.

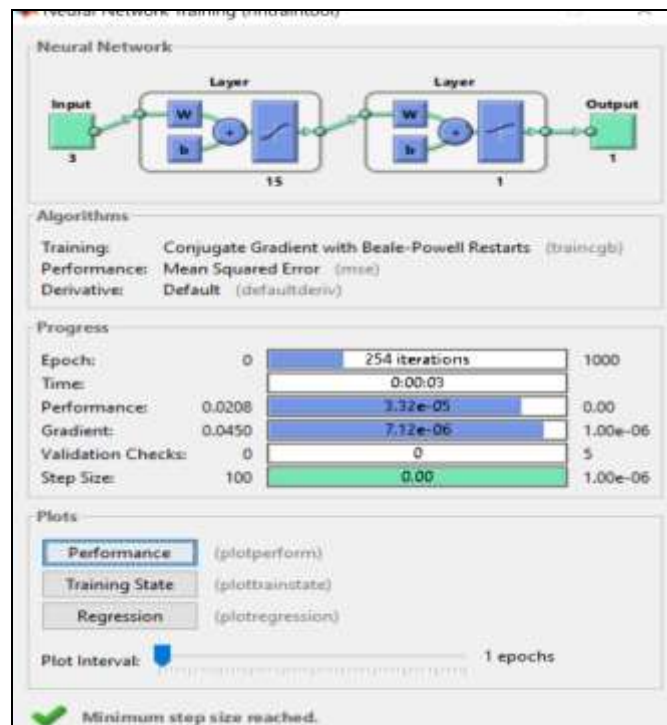
**Tabel 8.** Hasil Pelatihan

Negara Asal	X1	X2	X3	Target	Actual	Error	Perf
Tiongkok	0,4560	0,6620	0,5143	0,4943	0,4943	0,0000	
Australia	0,4028	0,2685	0,2196	0,2574	0,2574	0,0000	
Uni,Emirat,Arab	0,2001	0,2146	0,1858	0,2292	0,2293	-0,0001	
Malaysia	0,1945	0,1577	0,1767	0,1959	0,1952	0,0007	
Amerika Serikat	0,1640	0,1532	0,1626	0,1462	0,1474	-0,0012	0,00003320
Korea Selatan	0,1837	0,1705	0,1506	0,1694	0,1696	-0,0002	
Singapura	0,1153	0,1283	0,1433	0,1791	0,1769	0,0022	
Qatar	0,1361	0,1292	0,1574	0,1607	0,1650	-0,0043	
Thailand	0,1216	0,1165	0,1203	0,1343	0,1207	0,0136	
Jepang	0,1107	0,1059	0,1042	0,1023	0,1133	-0,0110	

**Tabel 9.** Hasil Pengujian

Negara Asal	X4	X5	X6	Target	Actual	Error	Perf
Tiongkok	0,6960	0,9000	0,7544	0,6210	0,4638	0,1572	
Australia	0,2684	0,2496	0,1976	0,1914	0,3946	-0,2032	
Uni,Emirat,Arab	0,2208	0,2195	0,2203	0,1571	0,2994	-0,1423	0,03985209
Malaysia	0,2005	0,2200	0,2140	0,1839	0,2568	-0,0729	
Amerika Serikat	0,1817	0,3021	0,3591	0,3153	0,8681	-0,5528	

Negara Asal	X4	X5	X6	Target	Actual	Error	Perf
Korea Selatan	0,1712	0,1610	0,1701	0,1497	0,1590	-0,0093	
Singapura	0,1604	0,1387	0,1323	0,1482	0,1244	0,0238	
Qatar	0,1356	0,1270	0,1233	0,1093	0,1125	-0,0032	
Thailand	0,1389	0,1287	0,1247	0,1228	0,1127	0,0101	
Jepang	0,1003	0,1039	0,1020	0,1000	0,1242	-0,0242	



**Gambar 5.** Pelatihan dengan Matlab (3-15-1)

### 3.3.4 Model 3-20-1

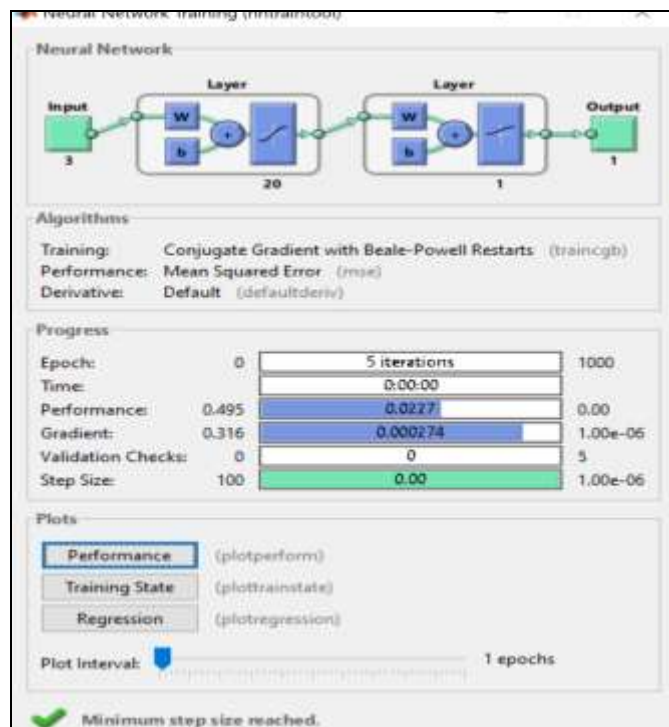
Hasil pelatihan dengan menggunakan model arsitektur 3-20-1 dapat dilihat pada gambar 6. Hasil pelatihan dengan menggunakan model ini menghasilkan epoch sebesar 5 iterasi.

**Tabel 10.** Hasil Pelatihan

Negara Asal	X1	X2	X3	Target	Actual	Error	Perf
Tiongkok	0,4560	0,6620	0,5143	0,4943	0,4945	-0,0002	
Australia	0,4028	0,2685	0,2196	0,2574	0,2590	-0,0016	
Uni,Emirat,Arab	0,2001	0,2146	0,1858	0,2292	0,0001	0,2291	
Malaysia	0,1945	0,1577	0,1767	0,1959	0,0001	0,1958	
Amerika Serikat	0,1640	0,1532	0,1626	0,1462	0,0000	0,1462	
Korea Selatan	0,1837	0,1705	0,1506	0,1694	0,0000	0,1694	0,022727648
Singapura	0,1153	0,1283	0,1433	0,1791	0,0000	0,1791	
Qatar	0,1361	0,1292	0,1574	0,1607	0,0000	0,1607	
Thailand	0,1216	0,1165	0,1203	0,1343	0,0000	0,1343	
Jepang	0,1107	0,1059	0,1042	0,1023	0,0000	0,1023	

**Tabel 11.** Hasil Pengujian

Negara Asal	X4	X5	X6	Target	Actual	Error	Perf
Tiongkok	0,6960	0,9000	0,7544	0,6210	0,7883	-0,1673	
Australia	0,2684	0,2496	0,1976	0,1914	0,0031	0,1883	
Uni,Emirat,Arab	0,2208	0,2195	0,2203	0,1571	0,0004	0,1567	
Malaysia	0,2005	0,2200	0,2140	0,1839	0,0002	0,1837	
Amerika Serikat	0,1817	0,3021	0,3591	0,3153	0,0023	0,3130	
Korea Selatan	0,1712	0,1610	0,1701	0,1497	0,0000	0,1497	0,03010927
Singapura	0,1604	0,1387	0,1323	0,1482	0,0000	0,1482	
Qatar	0,1356	0,1270	0,1233	0,1093	0,0000	0,1093	
Thailand	0,1389	0,1287	0,1247	0,1228	0,0000	0,1228	
Jepang	0,1003	0,1039	0,1020	0,1000	0,0000	0,1000	



**Gambar 6.** Pelatihan dengan Matlab (3-20-1)

### 3.3.5 Model 3-25-1

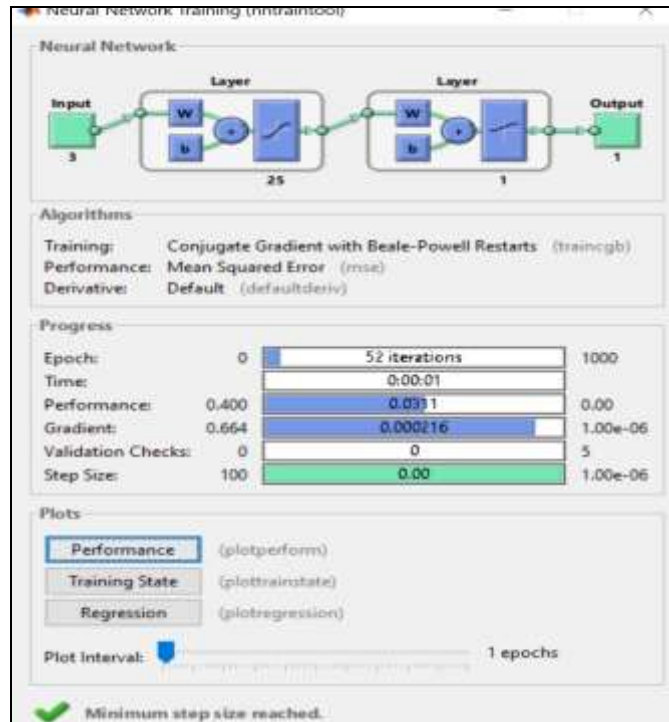
Hasil pelatihan dengan menggunakan model arsitektur 3-25-1 dapat dilihat pada gambar 7. Hasil pelatihan dengan menggunakan model ini menghasilkan epoch sebesar 52 iterasi.

**Tabel 12.** Hasil Pelatihan

Negara Asal	X1	X2	X3	Target	Actual	Error	Perf
Tiongkok	0,4560	0,6620	0,5143	0,4943	0,0000	0,4943	0,03109614
Australia	0,4028	0,2685	0,2196	0,2574	0,0000	0,2574	
Uni,Emirat,Arab	0,2001	0,2146	0,1858	0,2292	0,2333	-0,0041	
Malaysia	0,1945	0,1577	0,1767	0,1959	0,1917	0,0042	
Amerika Serikat	0,1640	0,1532	0,1626	0,1462	0,1556	-0,0094	
Korea Selatan	0,1837	0,1705	0,1506	0,1694	0,1663	0,0031	
Singapura	0,1153	0,1283	0,1433	0,1791	0,1752	0,0039	
Qatar	0,1361	0,1292	0,1574	0,1607	0,1587	0,0020	
Thailand	0,1216	0,1165	0,1203	0,1343	0,1260	0,0083	
Jepang	0,1107	0,1059	0,1042	0,1023	0,1128	-0,0105	

**Tabel 13.** Hasil Pengujian

Negara Asal	X4	X5	X6	Target	Actual	Error	Perf
Tiongkok	0,6960	0,9000	0,7544	0,6210	0,0000	0,6210	0,066538109
Australia	0,2684	0,2496	0,1976	0,1914	0,6853	-0,4939	
Uni,Emirat,Arab	0,2208	0,2195	0,2203	0,1571	0,2425	-0,0854	
Malaysia	0,2005	0,2200	0,2140	0,1839	0,2171	-0,0332	
Amerika Serikat	0,1817	0,3021	0,3591	0,3153	0,1544	0,1609	
Korea Selatan	0,1712	0,1610	0,1701	0,1497	0,1636	-0,0139	
Singapura	0,1604	0,1387	0,1323	0,1482	0,1239	0,0243	
Qatar	0,1356	0,1270	0,1233	0,1093	0,1206	-0,0113	
Thailand	0,1389	0,1287	0,1247	0,1228	0,1205	0,0023	
Jepang	0,1003	0,1039	0,1020	0,1000	0,1236	-0,0236	



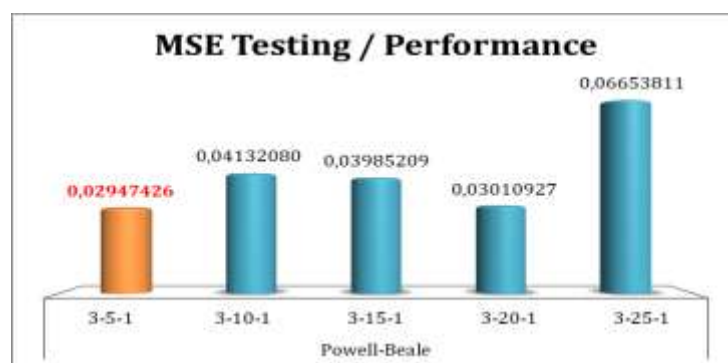
**Gambar 7.** Pelatihan dengan Matlab (3-25-1)

### 3.4 Evaluasi

Setelah dilakukan pelatihan dan pengujian data terhadap model arsitektur 3-5-1, 3-10-1, 3-15-1, 3-20-1 dan 3-25-1 menggunakan bantuan tools Matlab dan Microsoft Excel, maka diperoleh model arsitektur terbaik 3-5-1 dengan nilai Performance/MSE pengujian yang paling rendah sebesar 0,02947426.

**Tabel 14.** Perbandingan Hasil Keseluruhan Model

Algoritma	Arsitektur	Epoch (Iterasi)	MSE Training	MSE Testing / Performance
Powell-Beale	3-5-1	165	0,000035884	0,02947426
	3-10-1	7	0,000493182	0,04132080
	3-15-1	254	0,000033199	0,03985209
	3-20-1	5	0,022727648	0,03010927
	3-25-1	52	0,031096140	0,06653811



**Gambar 8.** Grafik Perbandingan MSE Pengujian / Performance

## 4. KESIMPULAN

Berdasarkan hasil dan pembahasan, maka dapat disimpulkan bahwa Algoritma Conjugate Gradient Powell-Beale dengan model arsitektur 3-5-1 dapat digunakan dan dimanfaatkan untuk melakukan prediksi impor aluminium di Indonesia menurut negara asal utama, karena waktu perlatihan untuk pencapaian konvergensi tidak terlalu lama dan Performance yang dihasilkan cukup baik dibandingkan empat model arsitektur yang lain. Secara keseluruhan dapat pula disimpulkan bahwa algoritma Powell-Beale (traincgb) mampu menghasilkan tingkat keoptimalan yang baik, yaitu menghasilkan nilai Performance / MSE pengujian yang (rendah), waktu untuk mencapai konvergensi dan iterasi yang relatif cepat.

## REFERENCES

- [1] S. Hodijah and G. . Angelina, "Analisis Pengaruh Ekspor Dan Impor Terhadap Pertumbuhan Ekonomi Di Indonesia," *Jurnal Manajemen Terapan dan Keuangan (Mankeu)*, vol. 10, no. 01, pp. 53–62, 2021.
- [2] A. Wanto, "Optimasi Prediksi Dengan Algoritma Backpropagation Dan Conjugate Gradient Beale-Powell Restarts," *Jurnal Teknologi dan Sistem Informasi*, vol. 3, no. 3, pp. 370–380, Jan. 2017.
- [3] H. Zhu, J. Leandro, and Q. Lin, "Optimization of Artificial Neural Network (ANN) for Maximum Flood Inundation Forecasts," *Water (Switzerland)*, vol. 13, no. 16, pp. 1–15, 2021.
- [4] A. Perera, H. M. D. Azamathulla, and U. Rathnayake, "Comparison of different artificial neural network (ANN) training algorithms to predict the atmospheric temperature in Tabuk, Saudi Arabia," *Mausam*, vol. 71, no. 2, pp. 233–244, 2020.
- [5] A. Wanto, M. Zarlis, Sawaluddin, and D. Hartama, "Analysis of Artificial Neural Network Backpropagation Using Conjugate Gradient Fletcher Reeves in the Predicting Process," *Journal of Physics: Conference Series*, vol. 930, no. 1, pp. 1–7, 2017.
- [6] B. Keshtegar, M. Hasanipناه, I. Bakhshayeshi, and M. Esfandi Sarafraz, "A novel nonlinear modeling for the prediction of blast-induced airblast using a modified conjugate FR method," *Measurement: Journal of the International Measurement Confederation*, vol. 131, pp. 35–41, 2019.
- [7] M. H. Tinambunan, E. B. Nababan, and B. B. Nasution, "Conjugate Gradient Polak Ribiere in Improving Performance in Predicting Population Backpropagation," *IOP Conference Series: Materials Science and Engineering*, vol. 835, no. 1, pp. 1–6, 2020.
- [8] G. W. Bhawika *et al.*, "Implementation of ANN for Predicting the Percentage of Illiteracy in Indonesia by Age Group," *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [9] A. Wanto *et al.*, "Analysis of the Backpropagation Algorithm in Viewing Import Value Development Levels Based on Main Country of Origin," *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [10] E. Siregar, H. Mawengkang, E. B. Nababan, and A. Wanto, "Analysis of Backpropagation Method with Sigmoid Bipolar and Linear Function in Prediction of Population Growth," *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [11] M. K. Z. Sormin, P. Sihombing, A. Amalia, A. Wanto, D. Hartama, and D. M. Chan, "Predictions of World Population Life Expectancy Using Cyclical Order Weight / Bias," *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [12] A. Wanto *et al.*, "Analysis of the Accuracy Batch Training Method in Viewing Indonesian Fisheries Cultivation Company Development," *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [13] Y. Andriani, H. Silitonga, and A. Wanto, "Analisis Jaringan Syaraf Tiruan untuk prediksi volume ekspor dan impor migas di Indonesia," *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 4, no. 1, pp. 30–40, 2018.
- [14] W. Saputra, J. T. Hardinata, and A. Wanto, "Implementation of Resilient Methods to Predict Open Unemployment in Indonesia According to Higher Education Completed," *JITE (Journal of Informatics and Telecommunication Engineering)*, vol. 3, no. 1, pp. 163–174, 2019.
- [15] N. L. W. S. R. Ginantra *et al.*, "Performance One-step secant Training Method for Forecasting Cases," *Journal of Physics: Conference Series*, vol. 1933, no. 1, pp. 1–8, 2021.