

Penerapan Algoritma *Backpropagation* Dalam Memprediksi Jumlah Pengguna Kereta Api Di Pulau Sumatera

Vivi Auladina¹, Jaya Tata Hardinata², M. Fauzan³

^{1,2,3}STIKOM Tunas Bangsa, Pematangsiantar, Sumatera Utara, Indonesia

Jln. Sudirman Blok A No. 1-3 Pematangsiantar, Sumatera Utara

¹viviauladina@gmail.com, ²jayatatahardinata@gmail.com

Abstract

The purpose of this study is to analyze and test whether the number of train passengers in Indonesia can be predicted by using artificial intelligence techniques. In this study, the artificial intelligence technique used is the Artificial Neural Network Technique (ANN) with the Backpropagation method. Artificial neural network is a method that has been widely used to solve forecasting cases. The main difficulties in implementing neural network methods in forecasting are finding the right architectural combination, determining the appropriate learning rate parameter values and selecting the optimal training algorithm. The research data is secondary data sourced from the bps.go.id website from 2006 - 2019. The data in this study were computerized using the matlab application. From the 5 architectural models used, the best model based on computerized results with the Matlab application is 3-3-1 with an output value of 0.0215923 MSE. The accuracy of the truth obtained is 92%.

Keywords : Railways, ANN, Prediction, Backpropagation

Abstrak

Tujuan dari penelitian ini adalah untuk menganalisa dan menguji apakah jumlah penumpang kereta api di Indonesia dapat diprediksi dengan menggunakan teknik kecerdasan buatan. Pada penelitian ini teknik kecerdasan buatan yang digunakan adalah Teknik Jaringan Saraf Tiruan (JST) dengan metode Backpropagation. Jaringan syaraf tiruan merupakan salah satu metode yang telah banyak digunakan untuk menyelesaikan kasus peramalan. Kesulitan utama dalam implementasi metode jaringan syaraf tiruan dalam peramalan adalah menemukan kombinasi arsitektur yang tepat, menentukan nilai parameter laju pembelajaran yang sesuai dan pemilihan algoritma pelatihan yang optimal. Data penelitian merupakan data sekunder yang bersumber dari website bps.go.id dari tahun 2006 – 2019. Data pada penelitian ini di uji secara komputerisasi menggunakan aplikasi matlab. Dari 5 model arsitektur yang digunakan diperoleh model terbaik berdasarkan hasil komputerisasi dengan aplikasi matlab adalah 3-3-1 dengan output nilai MSE 0,0215923. Akurasi kebenaran yang diperoleh adalah 92%.

Kata Kunci : Kereta Api, JST, Prediksi, Backpropagation

1. Pendahuluan

Pada zaman ini kereta api telah menjadi salah satu moda transportasi andalan masyarakat Indonesia untuk melakukan perjalanan jarak menengah dan jauh, khususnya di Pulau Sumatera. Kereta api menjadi transportasi paling diminati masyarakat dikarenakan harganya yang lebih murah ketimbang transportasi lainnya. Data dari laporan tahunan PT. Kereta Api Indonesia (PT. KAI) tahun 2015, PT KAI telah mengangkut penumpang sebanyak 327,2 juta pada tahun 2015. Jumlah penumpang naik 16,73% dibandingkan tahun 2014 mencapai 280,3 juta penumpang (Laporan Tahunan PT. KAI Persero Tahun 2015). Tingginya minat masyarakat terhadap angkutan kereta api, menjadi nilai tambah bagi perusahaan untuk dapat memberikan pelayanan yang maksimal. Oleh karena itu, peramalan tentang jumlah

pengguna kereta api menjadi hal yang penting bagi perusahaan untuk mengetahui jumlah pengguna jasa layanan kereta api di masa yang akan datang.

Dengan semakin majunya ilmu pengetahuan dan teknologi dari berbagai disiplin ilmu, saat ini prediksi atau peramalan dapat dilakukan dengan pendekatan-pendekatan empiris, salah satunya dengan menggunakan Jaringan Saraf Tiruan (JST). [1] menyimpulkan bahwa salah satu keunggulan dari JST adalah kemampuan klasifikasi terhadap data yang belum diberikan pada saat pembelajaran sebelumnya. Ada beberapa metode pada JST salah satunya adalah metode *Backpropagation*. Banyak penelitian terkait *backpropagation* yang mampu menyelesaikan masalah prediksi dengan nilai akurasi prediksi yang tinggi. Salah satunya adalah penelitian yang dilakukan oleh [2] tentang prediksi indeks harga konsumen berdasarkan kelompok kesehatan. Hasil penelitian menyimpulkan bahwa algoritma *backpropagation* dapat digunakan pada prediksi indeks harga konsumen berdasarkan kelompok kesehatan dengan menggunakan 8 model arsitektur, yakni : 12-5-1 dengan tingkat akurasi sebesar 58%, 12-26-1 = 58%, 12-29-1 = 75%, 12-35-1 = 50% , 12-40-1 = 42%, 12-60-1 = 67%, 12-70-1 = 92% dan 12-75-1 = 50%. Dari uji model diperoleh model terbaik 12-70-1 dengan tingkat akurasi sebesar 92%, MSE 0,3659742 dengan tingkat error yang digunakan 0,001 – 0,05.

Oleh karena itu, dalam penelitian ini metode *backpropagation* dipilih untuk memprediksi jumlah penumpang kereta api di Pulau Sumatera. Penelitian ini akan dilakukan dengan mengeksplorasi parameter *backpropagation* seperti laju pembelajaran (*learning rate*) dan arsitektur jaringan. Lebih lanjut, hasil penelitian ini diharapkan dapat membantu memberikan informasi bagi para pengambil keputusan untuk lebih meningkatkan pengguna kereta api dimasa yang akan datang, Karena hal ini berdampak kepada peningkatan *income* pada PT.KAI Persero.

2. Metodologi Penelitian

2.1. Jaringan Saraf Tiruan

Jaringan Saraf Tiruan (JST) merupakan jaringan yang terdiri atas sekelompok unit pemroses kecil yang dimodelkan berdasarkan jaringan saraf manusia [3], [4]. JST tercipta sebagai suatu generalisasi model matematis dari pemahaman manusia (*human cognition*) yang didasarkan atas asumsi pemrosesan informasi terjadi pada elemen sederhana yang disebut *neuron*, sinyal mengalir diantara sel saraf/*neuron* melalui suatu sambungan penghubung, setiap sambungan penghubung memiliki bobot yang bersesuaian [5].

Konsep Dasar Pemodelan Jaringan Saraf Tiruan yaitu Setiap pola-pola informasi *input* dan *output* yang diberikan kedalam jaringan saraf tiruan diproses dalam *neuron*. *Neuron-neuron* tersebut terkumpul didalam lapisan-lapisan yang disebut *neuron layers* [6], [7].

2.2. Backpropagation

Model jaringan *Backpropagation* merupakan suatu teknik pembelajaran atau pelatihan *supervised leaning* yang paling banyak digunakan. Metode ini merupakan salah satu metode yang sangat baik dalam menangani masalah pengenalan pola-pola kompleks [8], [5]. Didalam jaringan *Backpropagation*, Setiap unit yang ada di lapisan tersembunyi terhubung dengan setiap unit yang ada di lapisan *output*. Jaringan ini terdiri dari banyak lapisan (*multilayer network*). [9].

Berikut adalah langkah-langkah cara kerja dari Algoritma Backpropagation:

- a) Dimulai dengan lapisan input, hitung output dari setiap elemen pemroses melalui lapisan input.
- b) Hitung *error* pada lapisan output yang merupakan selisih antara data aktual dan target.

- c) Transformasikan *error* tersebut pada bagian yang sesuai di sisi input elemen pemroses.
- d) Propagasi balik *error* ini pada output setiap elemen pemroses ke *error* yang terdapat pada input. Ulangi proses ini sampai input tercapai.
- e) Ubah seluruh bobot dengan menggunakan kesalahan pada sisi elemen input dan elemen output pemroses yang terhubung.

3. Hasil dan Pembahasan

Data yang digunakan dalam penelitian ini adalah data jumlah penumpang kereta api di pulau Sumatera selama kurun waktu 2006 – 2019. Sumber data penelitian diperoleh dari Badan Pusat Statistik dengan url: <https://bps.go.id/> seperti yang ditunjukkan pada tabel berikut:

Tabel 1. Data Jumlah Penumpang Kereta Api Wilayah Sumatera 2006-2019

Bulan	Jumlah Penumpang Kereta Api Wilayah Sumatera (Orang)													
	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
Januari	324	313	330	248	384	445	482	327	394	422	472	590	610	687
Februari	226	210	262	276	327	371	364	279	370	396	453	505	557	617
Maret	248	242	315	306	375	394	389	305	409	426	461	558	603	683
April	252	226	276	317	676	410	370	276	406	415	434	568	619	703
Mei	263	293	309	357	423	504	370	318	441	460	527	588	605	588
Juni	274	284	374	397	451	459	375	369	425	444	429	542	760	829
Juli	346	362	425	426	499	500	353	328	375	535	615	641	711	732
Agustus	264	275	339	323	337	354	381	392	436	445	463	536	630	647
September	253	241	275	441	588	568	305	299	374	424	497	577	626	606
Oktober	341	401	436	313	366	399	299	336	420	438	498	572	634	626
November	262	250	277	344	381	414	337	341	370	416	512	563	661	711
Desember	270	318	321	371	434	478	359	425	484	503	620	667	768	850

Dalam melakukan pelatihan dan pengujian, dilakukan normalisasi terlebih dahulu, agar dapat lebih mudah melakukan pelatihan data menggunakan aplikasi *matlab R2011b*. Formula normalisasi dapat dilihat pada persamaan berikut:

$$x' = \frac{0.8(x-a)}{b-a} + 0.1 \quad (1)$$

Keterangan :

x' : Data yang telah ditransformasi

X : Data yang akan dinormalisasi

a : Data minimum

b : Data maksimum

Data dibagi menjadi dua yakni data pelatihan (*training*) dan data pengujian (*testing*). Data normalisasi dapat dilihat pada tabel 2 dan 3 :

Tabel 2. Data *Training* Sebelum di Normalisasi

No	Bulan / Tahun	2017	2018	2019	2020
1	Januari	590	610	687	658
2	Februari	505	557	617	604
3	Maret	558	603	683	476
4	April	568	619	703	85
5	Mei	588	605	588	571
6	Juni	542	760	829	898
7	Juli	641	711	732	753
8	Agustus	536	630	647	664
9	September	577	626	606	586
10	Oktober	572	634	634	634

No	Bulan / Tahun	2017	2018	2019	2020
11	November	563	661	649	637
12	Desember	667	768	753	738

Data pada tabel 2 adalah data *training* yang akan dinormalisasi yakni data pada tahun 2017 – 2019 sedangkan yang sebagai target adalah data pada tahun 2020. Dengan menggunakan fungsi sigmoid biner maka diperoleh data normalisasi dengan ketentuan, pada masing – masing bulan dengan nilai Maksimum (b) sebesar 898 dan nilai Minimum (a) sebesar 85, Misal:

$$X^{1,1} = \frac{0,8(590-85)}{813-85} + 0,1 = 0,5969$$

$$X^{1,2} = \frac{0,8(505-85)}{813-85} + 0,1 = 0,5133$$

Data *training* dapat dilihat pada tabel 3 berikut:

Tabel 3. Data *Training* Sesudah dinormalisasi

No	Bulan / Tahun	X1	X2	X3	Target
1	Januari	0,5969	0,6166	0,6924	0,6638
2	Februari	0,5133	0,5645	0,6235	0,6107
3	Maret	0,5654	0,6097	0,6884	0,4847
4	April	0,5753	0,6255	0,7081	0,1000
5	Mei	0,5950	0,6117	0,5950	0,5782
6	Juni	0,5497	0,7642	0,8321	0,9000
7	Juli	0,6471	0,7160	0,7367	0,7573
8	Agustus	0,5438	0,6363	0,6530	0,6697
9	September	0,5841	0,6323	0,6127	0,5930
10	Oktober	0,5792	0,6402	0,6402	0,6402
11	November	0,5704	0,6668	0,6550	0,6432
12	Desember	0,6727	0,7721	0,7573	0,7426

Pada tabel 3 menjelaskan bahwa data *testing* yang sudah dinormalisasikan tahun 2017 – 2020 sedangkan sebagai target yakni tahun 2020. Maksimum dan Minimum ditentukan berdasarkan dari semua data yang akan dilakukan pelatihan (data *Training*). Berikut ini adalah data *testing* sebelum dinormalisasi dapat dilihat pada tabel 4:

Tabel 4. Data *Testing* Sebelum dinormalisasi

No	Bulan / Tahun	2018	2019	2020	2021
1	Januari	610	687	658	629
2	Februari	557	617	604	591
3	Maret	603	683	476	269
4	April	619	703	85	533
5	Mei	605	588	571	554
6	Juni	760	829	898	967
7	Juli	711	732	753	774
8	Agustus	630	647	664	681
9	September	626	606	586	566
10	Oktober	634	634	634	634
11	November	661	649	637	625
12	Desember	768	753	738	723

Data pada tabel 4 adalah data *testing* yang belum dinormalisasikan, untuk *testing* yakni data tahun 2018 -2020 sedangkan yang sebagai target data tahun 2021. Dengan menggunakan fungsi sigmoid biner maka diperoleh data normalisasi dengan

ketentuan, pada masing – masing produk bulan dengan nilai Maksimum (b) sebesar 967 dan nilai Minimum (a) sebesar 85, perhatikan 3 (tiga) contoh berikut:

$$X^{1,1} = \frac{0,8(610-85)}{882-85} + 0,1 = 0,5762$$

$$X^{1,2} = \frac{0,8(557-85)}{882-85} + 0,1 = 0,5281$$

Berikut data *testing* sudah dinormalisasi dapat dilihat pada tabel 5:

Tabel 5. Data *Testing* Sesudah dinormalisasi

No	Bulan / Tahun	X1	X2	X3	Target
1	Januari	0,5762	0,6460	0,6197	0,5934
2	Februari	0,5281	0,5825	0,5707	0,5590
3	Maret	0,5698	0,6424	0,4546	0,2669
4	April	0,5844	0,6605	0,1000	0,5063
5	Mei	0,5717	0,5562	0,5408	0,5254
6	Juni	0,7122	0,7748	0,8374	0,9000
7	Juli	0,6678	0,6868	0,7059	0,7249
8	Agustus	0,5943	0,6098	0,6252	0,6406
9	September	0,5907	0,5726	0,5544	0,5363
10	Oktober	0,5980	0,5980	0,5980	0,5980
11	November	0,6224	0,6116	0,6007	0,5898
12	Desember	0,7195	0,7059	0,6923	0,6787

Pada tabel 5 menjelaskan bahwa data *testing* yang sudah dinormalisasikan tahun 2018 – 2020 sedangkan sebagai target yakni tahun 2021. Maksimum dan Minimum ditentukan berdasarkan dari semua data yang akan dilakukan pengujian (data *Training*). Perhitungan manual hanya dilakukan pada sampel data *Input*, berikut tahapan-tahapan yang dilakukan :

Tahap initialitation

a) Tahapan dalam proses inialisasi ini adalah menginisialisasi data *Input*, bobot dari *Input* ke pada hidden layer lalu ke *output* layer. Yang akan menjadi nilai *Input* adalah X1-Xn, dengan menggunakan :

$$Learning\ Default = 0,01 \quad Epocs = 500.000 \quad Goal = 0,1$$

Variabel *Input* terdiri dari

$$X1 = 0,5969$$

$$X2 = 0,6166$$

$$X3 = 0,6923$$

b) Berikan nilai bobot dari *Input* ke hidden layer. Pada tabel 6 dan 7 akan terlihat bobot dari *Input* layer ke hidden layer, dari hidden layer ke *output* yang penulis ambil dari Sistem *Matlab 6.1*.

Tabel 6. Bobot yang diberikan dari *Input* layer ke hidden layer

	V1	V2
X1	32,88	-31,67
X2	5,99	-1,27
X3	19,22	20,76
1	-40,74	1,29

Tabel 7. Bobot yang diberikan dari hidden layer ke ouput layer

	L
Z1	-0,0871
Z2	-0,963
1	0,6428

**Tahap 1: Perhitungan Maju :**

Perhitungan maju adalah perhitungan nilai *output* dari unit tersembunyi atau hidden layer, sebagaimana rumus yang telah dijelaskan pada landasan teori :

$$z_{net1} = V1 + (X1 * V11) + (X2 * V21) + (X3 * V31) = \quad (2)$$

$$-40,74 + (32,88 * 0,59) + (5,99 * 0,61) + (19,22 * 0,69) = -4,1154$$

$$z_{net2} = V2 + (X1 * V12) + (X2 * V22) + (X3 * V32) = \quad (3)$$

$$1,29 + (-31,67 * 0,59) + (-1,27 * 0,61) + (20,76 * 0,69) = -4,0261$$

1) Kemudian dilanjutkan dengan menghitung nilai keluaran dengan menggunakan fungsi aktivasi yang dipilih, di mana fungsi aktivasi yang digunakan adalah fungsi sigmoid biner,:

$$a) z1 = \text{sigmoid} [-4,1154] = \frac{1}{1 + e^{(-4,1154)}} = 0,01605$$

$$b) z2 = \text{sigmoid} [-4,0261] = \frac{1}{1 + e^{(-4,0261)}} = 0,01753$$

2) Menghitung nilai *output* pada unit yk ($k=1,2,3,\dots,m$) dengan menggunakan nilai bobot-nya:

$$Y_{ink} = N_{JII} = 0,6428 + (-0,0871 * -4,1154) + (-0,963 * -4,0261) = 4,8784$$

Kemudian dihitung nilai *Output* dengan menggunakan fungsi aktivasi : sigmoid

$$[4,8784] = \frac{1}{1 + e^{(4,8784)}} = 0,9924$$

Tahap 2: Perhitungan Mundur:

1) Untuk tiap unit keluaran (yk , $k=1,\dots,m$) menerima pola target yang bersesuaian dengan pola masukan, dan kemudian dihitung informasi kesalahan Hitung faktor δ diunit keluaran berdasarkan kesalahan setiap unit keluaran yk , rumus yang digunakan berdasarkan rujukan pada (2.5a)

$$\delta_1 = (0,6638 - 0,9924) * 0,9924 * (1 - 0,9924) = -0,0025$$

2) Suku perubahan bobot W_{jk} dilakukan perhitungan (yang akan digunakan untuk merubah bobot W_{jk}) dengan laju pelatihan *learning rate* $\alpha=0,1$,

$$\Delta W_{10} = 0,1 * -0,0025 * 1 = -0,00024$$

$$\Delta W_{11} = 0,1 * -0,0025 * -4,1154 = 0,00101$$

$$\Delta W_{12} = 0,1 * -0,0025 * -4,0261 = 0,00099$$

3) Untuk setiap (Z_j , $j=1,\dots,p$) dihitung delta masukan yang berasal dari neuron pada layer di atasnya,):

$$\delta_{net1} = -0,0025 * -0,0871 = 0,00021$$

$$\delta_{net2} = -0,0025 * -0,963 = 0,00237$$

4) Kemudian nilai tersebut dikalikan dengan nilai turunan dari fungsi aktivasi untuk menghitung informasi kesalahan,:

$$\delta_1 = 0,0126 * 0,0480 * (1 - 0,0480) = 0,0006$$

$$\delta_2 = 0,1392 * 0,6933 * (1 - 0,6933) = 0,0296$$

5) Hitung koreksi nilai bobot yang kemudian digunakan untuk memperbaharui v_{ij} ,:

$$\Delta v_{11} = 0,2 * 0,5969 * 4,0458 = -0,2496$$

$$\Delta v_{21} = 0,2 * 0,5969 * 4,8767 = -2,7880$$

Perhitungan dilanjutkan, sehingga di dapatkan data sebagai berikut :

Tabel 8. Koreksi Nilai Bobot

Baru	V1	V2
X1	-0,2496	-2,7880
X2	-0,2496	-2,7880

$$W_1 (\text{baru}) = 0,00101 + -0,0871 = -0,9619$$

$$W_2 (\text{baru}) = 0,00099 + -0,963 = -0,9620$$

Bobot garis mengalami perubahan pada saat terhubung ke hidden layer:

$$V_{11} (\text{baru}) = -0,2496 + 32,8822 = 32,8822$$

$$V_{21} (\text{baru}) = -0,2496 + 5,9928 = 5,9928$$

$$V_{31} (\text{baru}) = -0,2496 + 19,2171 = 19,2171$$

Tabel 9. Perubahan Bobot Akhir Pada P=1 Dari *Input* Ke Hiden Layer

	V1	V2
X1	3,28822	-31,6729
X2	5,99280E	-1,2678
X3	1,92171	20,7577

Tabel 10. Perubahan Bobot Akhir Pada P=1 Dari Hidden Ke *Output* Layer

	L
Z1	-0,96199
Z2	-0,96201
1	0,6428

Setelah hasil perubahan bobot dan bias pada proses iterasi pertama selesai dilakukan maka akan menghasilkan nilai perubahan bobot dan bias yang baru melalui proses pelatihan. Proses pelatihan jaringan akan dilanjutkan secara berkelanjutan sampai nantinya menghasilkan nilai *output* dan juga nilai *error* yang terkecil. Untuk hasil dari iterasi pertama dari data baris pertama dari perhitungan manual berikut dengan *output* sebagai berikut : $Y_{ink}=N_{JII} = 0,6428 + (-0,0871 * -4,1154) + (-0,963 * -4,0261) = 4,8784$.

Kemudian dihitung nilai *Output* dengan menggunakan fungsi aktivasi : sigmoid $[4,8784 = \frac{1}{1+e^{(4,8784)}} = 0,9924$.

Setelah itu hasil *output* jst dikurangkan dengan target untuk menghitung margin error : $Output\ Jst - Target$

$$0,9924 - 0,5969 = 0,3958.$$

Setelah terlihat dari hasil nilai iterasi pertama dengan nilai 0,3958 dapat menjelaskan bahwa perlu adanya pembelajaran data untuk memaksimalkan *performance* data yang diuji. Tidak sampai disitu saja dilakukan juga proses pengujian dengan pola yang sudah di tentukan, proses ini berguna untuk mendapatkan keakuratan antara pelatihan dan pengujian sehingga didapatkan kesimpulan korelasi peningkatan iklim penelitian dengan beban kerja dosen. Maka Untuk mempercepat proses dari pemecahan masalah dari penelitian ini, maka penulis menggunakan sebuah alat bantu program berupa *Software Matlab 6.1*, karena *software Matlab 6.1* didesain dengan sedemikian rupa dengan mengadaptasi dari algoritma yang penulis gunakan pada penelitian ini. Hasil *software* aplikasi *Matlab 6.1* yang digunakan untuk model arsitektur 3-3-1, arsitektur 3-5-1, arsitektur 3-7-1, arsitektur 3-2-2-1 dan arsitektur 3-3-3-1 adalah 3-3-1. memperoleh pola arsitektur terbaik. Dari pola ini nanti akan digunakan untuk mempredikasi korelasi beban kerja dosen terhadap peningkatan jumlah publikasi. Penilaian model arsitektur terbaik dilihat dari beberapa aspek seperti *epoch*, *error minimum* dan akurasi kebenaran. Untuk lebih jelas dapat dilihat pada berikut :

Tabel 11. Rekapitulasi Model Arsitektur

Arsitektur	Training			Testing	
	Epoch	MSE	Akurasi	MSE	Akurasi
3-3-1	29	0,1014170	92	0,0215923	92
3-5-1	268	0,0999669	42	0,1405308	17
3-7-1	167	0,0996436	75	0,1532265	67
3-2-2-1	455	0,0999869	75	0,1224289	75
3-3-3-1	38	0,0996698	8	0,0804625	33

Dari data yang didapat, bahwa *performance* perhitungan jaringan saraf tiruan dengan Algoritma *Backpropagation* adalah 92%. Dapat dilihat dengan perbandingan target yang diinginkan dengan target prediksi. Jumlah peningkatan pengguna kereta

Api di Sumatera berdasarkan tabel 11. menunjukkan bahwa peningkatan pengguna pada tahun 2021 di Sumatera terletak pada skala besar. Dan jaringan saraf tiruan dengan menggunakan algoritma backpropagation dapat diterapkan dalam menganalisa prediksi peningkatan pengguna kereta Api antara Tahun priode sebelumnya dengan tahun sekarang untuk memprediksi data yang akan datang dengan menentukan model arsitektur terbaik dari serangkain proses training dan testing yang dilakukan.

4. Kesimpulan

Berdasarkan hasil penelitian yang dilakukan, penulis menarik beberapa kesimpulan diantaranya:

- a) Metode yang digunakan dalam penelitian ini adalah Algoritma Backpropagation untuk memprediksi jumlah pengguna Kereta Api di Pulau Sumatera.
- b) Jaringan saraf tiruan dengan metode *backpropagation* dapat diterapkan untuk kasus memprediksi pengguna kereta api di Pulau Sumatera dengan mengubah parameter (*learning rate*) untuk meningkatkan hasil akurasi. Dari 5 model arsitektur yang digunakan diperoleh model terbaik dalam melakukan prediksi adalah 3-3-1 dengan *output* nilai MSE 0,0215923. Akurasi kebenaran yang diperoleh adalah 92%.
- c) Model arsitektur jaringan yang digunakan sangat mempengaruhi tingkat training dan testing. Dengan melihat hasil pengujian, dapat diambil kesimpulan bahwa terjadi kecepatan dan hasil akurasi yang bervariasi pada 5 percobaan di setiap pengujian yang dilakukan.

Daftar Pustaka

- [1] A. Wanto, A. P. Windarto, D. Hartama, And I. Parlina, "Use Of Binary Sigmoid Function And Linear Identity In Artificial Neural Networks For Forecasting Population Density," *Int. J. Inf. Syst. Technol.*, Vol. 1, No. 1, Pp. 43–54, 2017.
- [2] 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>.
- [3] A. P. Windarto, "Implementasi Jst Dalam Menentukan Kelayakan Nasabah Pinjaman Kur Pada Bank Mandiri Mikro Serbelawan Dengan Metode Backpropagation," *J-Sakti (Jurnal Sains Komput. Dan Inform.*, Vol. 1, No. 1, Pp. 12–23, 2017.
- [4] T. Dalglish *Et Al.*, *Jaringan Syaraf Tiruan (Neural Network)*, Vol. 136, No. 1. 2014.
- [5] Z. A. Matodang, "Jaringan Syaraf Tiruan Dengan Algoritma Backpropagation Untuk Penentuan Kelulusan Sidang Skripsi," *Pelita Inform. Budi Darma*, Vol. 4, No. 1, Pp. 84–93, 2013.
- [6] A. P. Windarto, L. S. Dewi, And D. Hartama, "Implementation Of Artificial Intelligence In Predicting The Value Of Indonesian Oil And Gas Exports With Bp Algorithm," *Int. J. Recent Trends Eng. Res.*, Vol. 3, No. 10, Pp. 1–12, 2017, Doi: 10.23883/Ijrt.2017.3482.J5bbs.
- [7] W. Budiharto And D. Suhartono, *Artificial Intelligence Konsep Dan Penerapannya*, Andi Yogya. Yogyakarta, 2014.
- [8] Y. A. Lesnussa, S. Latuconsina, And E. R. Persulesy, "Aplikasi Jaringan Saraf Tiruan Backpropagation Untuk Memprediksi Prestasi Siswa Sma (Studi Kasus : Prediksi Prestasi Siswa Sman 4 Ambon)," Vol. 11, No. 2, Pp. 149–160, 2015.
- [9] N. M. Sukarno, P. W. Wirawan, And S. Adhy, "Perancangan Dan Implementasi Jaringan Saraf Tiruan," Vol. 5, Pp. 9–18, 2013.