



METODE FLETCHER-REVEES DALAM MEMPREDIKSI PENGELUARAN RATA-RATA PER KAPITA SEBULAN UNTUK MAKANAN DI DAERAH PERKOTAAN MENURUT PROVINSI

Randi Ardiansyah Darmadi¹, Solikhun²

^{1,2}Teknik Informatika, STIKOM Tunas Bangsa Pematangsiantar, Indonesia

Article Info

Article history:

Received Aug 29, 2023

Revised Aug 30, 2023

Accepted Aug 31, 2023

Kata Kunci:

Jaringan Syaraf Tiruan

Backpropagation

Prediksi

Fletcher-Reeves

Pengeluaran Per Kapita

Keywords:

Artificial Neural Network

Backpropagation

Prediction

Fletcher-Reeves

Per Capita Spending

ABSTRAK

Pengeluaran perkapita cukup penting dalam analisis ekonomi dan sosial. Selain itu Pengeluaran perkapita juga memiliki tujuan dalam mengukur tingkat kesejahteraan, membandingkan dan menganalisis kinerja ekonomi, serta dapat pula mengatur kebijakan publik. Riset ini bertujuan buat menciptakan suatu arsitektur terbaik dengan memakai backpropagation dimana nantinya dicoba suatu prediksi terhadap pengeluaran rata-rata per kapita khususnya komoditi makanan di wilayah perkotaan di Indonesia. Variabel yang dipergunakan adalah data pengeluaran rata-rata perkapita yang pada mana datanya diperoleh asal situs Badan Pusat Statistik. Dari serangkaian uji coba pemilihan contoh arsitektur, terpilihlah 4 buah contoh arsitektur yakni: 14-5-1; 14-6-1; 14-7-1 dan 14-8-1. Diantara empat contoh arsitektur itu terpilihlah model arsitektur 14-5-1 menjadi model arsitektur terbaik dengan menerima jumlah epoch sebanyak 355 dan Mean Square Error (MSE) pengujian sebanyak 0,00099964 serta taraf akurasi pengujian sebesar 91%.

ABSTRACT

Per capita spending is of great importance in economic and social analysis. In addition, per capita spending can also be used to measure welfare levels, compare and analyze economic performance, and regulate public policy. This study aims to create the best architecture using backpropagation, followed by projections of average per capita expenditure, especially food, in urban areas of Indonesia. The variables used are his average per capita spending data taken from his website at the Central Statistics Office. From a series of architectural pattern selection attempts, his four architectural samples were selected: 14-5-1; 14-6-1; 14-7-1 and 14-8-1. Among the four architecture samples, the 14-5-1 architecture model was selected as the best architecture model as it got a total of 355 epochs, a mean squared error (MSE) test of 0.00099964, and a test accuracy of 91%.

This is an open access article under the [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) license.



Corresponding Author:

Randi Ardiansyah Darmadi,

Teknik Informatika, STIKOM Tunas Bangsa

Jl. Jend. Sudirman, Blok A. No.1,2&3, Siantar Barat, Pematang Siantar, Sumatera Utara, Indonesia.

Email: -

1. PENDAHULUAN

Pengeluaran rata-rata per kapita adalah biaya pengeluaran bulanan oleh semua anggota rumah tangga, seperti pembelian, sumbangan, dan produksi rumahan, dibagi dengan jumlah anggota rumah tangga. Hal ini mengacu pada total pengeluaran yang dibagi dengan jumlah penduduk di sebuah wilayah dalam periode waktu tertentu.

Pengeluaran rata-rata per kapita dapat dihitung dengan membagi total pengeluaran suatu wilayah, misalnya total pengeluaran suatu rumah tangga dengan jumlah penduduk yang tinggal di wilayah tersebut. Pengeluaran rata-rata per kapita hanya gambaran tingkat pengeluaran di daerah dan tidak memperhitungkan ketimpangan distribusi pendapatan. Beberapa individu dalam populasi mungkin memiliki pengeluaran yang jauh di atas atau di bawah rata-rata, sehingga angka ini mungkin tidak mencerminkan keadaan sebenarnya dari populasi secara keseluruhan.

Contohnya jika ada suatu total pengeluaran sebuah negara adalah \$1 triliun dengan jumlah penduduk yang mencapai 100 juta, maka total pengeluaran rata-rata perkapita akan menjadi \$10000. Berarti setiap individu di negara itu akan mengeluarkan rata-rata \$10000.

Rata-rata pengeluaran perkapita bisa menjadi bahan tolak ukur terhadap kemakmuran penduduk di suatu wilayah, serta bisa menjadi bahan acuan dalam membandingkan tingkat ekonomi antar negara. Tentunya penggunaan pengeluaran rata-rata perkapita harus dilakukan dengan mempertimbangkan berbagai aspek yang relevan demi mencapai pemahaman yang lebih komprehensif.

Kecerdasaan Buatan (*Artificial Intelligence*) dalam ilmu komputer banyak digunakan untuk menyelesaikan permasalahan yang berhubungan dengan prediksi, terutama yang berbasis pada data time-series (*history*). Salah satu cabang Kecerdasaan Buatan (*AI*) yang banyak digunakan untuk melakukan prediksi adalah Jaringan Syaraf Tiruan (*JST*) dengan algoritma Backpropagation (Aulia, 2018). Seperti pada prediksi index harga konsumen berdasarkan kelompok kesehatan (Wanto & Windarto, 2017), prediksi terhadap jumlah permintaan produksi (Thoriq, 2022), prediksi curah hujan kota (Andrian & Ningsih, 2014), prediksi data IHSG (Hansun, 2013), dan prediksi nilai ekspor (Saragih et al., 2018).

Penelitian ini menggunakan metode Backpropagation Neural Network untuk memprediksi besarnya Pengeluaran Rata-rata Per Kapita Sebulan untuk Makanan di daerah perkotaan di Indonesia yang dimana datanya diperoleh dari situs Badan Pusat Statistik (BPS) serta harapannya penelitian ini memperoleh hasil yang optimal dalam memprediksi besarnya pengeluaran rata-rata kelompok makanan untuk tahun-tahun kedepannya.

2. METODE PENELITIAN

Data merupakan komponen terpenting di dalam sebuah penelitian dimana datanya akan diolah sehingga menghasilkan suatu tujuan yang bermanfaat. Berikut ini merupakan data Pengeluaran rata-rata per kapita sebulan untuk makanan di daerah perkotaan di Indonesia untuk tahun 2007 hingga 2022.

Tabel 1. Data Pengeluaran Rata-rata Per Kapita untuk Makanan

Provinsi	Makanan										
	2007	2008	2009	2010	2011	(...)	2018	2019	2020	2021	2022
Aceh	51.86	50.87	55.17	52.58	50.68	(...)	50.14	49.96	48.19	50.35	50.68
Sumatera Utara	47.92	47.63	48.39	46.77	50.90	(...)	51.84	51.03	50.14	48.96	50.76
Sumatera Barat	49.62	51.28	51.20	51.30	51.56	(...)	48.45	48.33	48.12	48.44	49.21
Riau	44.94	46.46	49.92	49.61	45.77	(...)	46.42	45.94	45.02	45.14	47.25
Jambi	46.92	47.12	50.33	50.67	49.73	(...)	49.07	48.02	46.62	47.20	47.16
Sumatera Selatan	49.88	50.20	50.53	51.02	54.28	(...)	47.14	46.88	47.83	47.71	49.61
Bengkulu	44.98	46.38	49.26	49.73	48.91	(...)	42.46	42.77	42.68	43.99	46.38
Lampung	39.81	42.09	45.32	46.32	46.55	(...)	47.61	47.92	47.74	47.31	48.84
Kepulauan Bangka Belitung	54.75	51.77	49.37	49.77	50.68	(...)	47.47	47.75	48.75	49.04	50.91
Kepulauan Riau	42.68	44.13	46.79	48.63	45.95	(...)	46.77	43.66	44.49	44.11	45.38
DKI Jakarta	35.28	36.34	38.14	38.94	33.76	(...)	41.58	40.70	41.84	39.54	37.75
Jawa Barat	44.91	46.64	45.29	48.65	45.53	(...)	46.93	47.94	47.70	47.36	47.36

Provinsi	Makanan										
	2007	2008	2009	2010	2011	(...)	2018	2019	2020	2021	2022
Jawa Tengah	46.06	48.09	48.74	48.64	45.58	(...)	46.33	46.31	46.34	46.91	48.23
DI Yogyakarta	39.27	40.40	42.53	41.28	43.11	(...)	38.66	38.65	39.17	40.00	40.72
Jawa Timur	44.78	45.99	48.43	49.41	46.59	(...)	46.37	45.10	45.69	46.68	48.01
Banten	40.86	41.99	43.46	41.80	43.98	(...)	45.63	46.86	47.62	46.66	48.85
Bali	40.80	43.60	41.90	42.72	38.24	(...)	41.81	42.27	42.70	40.93	40.21
Nusa Tenggara Barat	51.45	51.98	48.04	47.57	52.71	(...)	54.68	50.62	50.63	50.93	54.85
Nusa Tenggara Timur	48.75	47.85	48.42	49.74	47.51	(...)	48.33	46.79	46.04	47.50	46.24
Kalimantan Barat	48.02	48.64	49.17	46.75	46.83	(...)	45.50	46.44	46.15	47.14	48.99
Kalimantan Tengah	50.53	54.23	53.81	54.01	51.97	(...)	46.67	46.62	45.85	46.74	48.11
Kalimantan Selatan	48.60	46.28	45.43	46.64	47.45	(...)	47.25	46.21	47.02	46.72	48.18
Kalimantan Timur	41.26	40.06	42.82	44.25	42.23	(...)	42.92	42.60	42.78	40.61	43.15
Kalimantan Utara	0.00	0.00	0.00	0.00	0.00	(...)	45.51	46.54	45.21	45.46	45.97
Sulawesi Utara	46.40	48.81	48.71	47.95	44.42	(...)	43.84	46.37	45.17	48.02	51.75
Sulawesi Tengah	49.17	47.77	44.22	41.90	46.35	(...)	43.34	46.09	43.40	43.09	46.08
Sulawesi Selatan	44.71	44.86	43.85	46.93	46.53	(...)	45.46	43.86	44.99	44.46	46.37
Sulawesi Tenggara	49.28	46.05	40.42	44.47	43.64	(...)	42.53	42.21	43.46	42.92	43.09
Gorontalo	43.10	47.85	50.62	48.45	46.48	(...)	43.40	40.79	39.60	42.63	40.04
Sulawesi Barat	59.64	56.29	51.22	49.23	54.00	(...)	47.41	46.54	44.44	43.98	43.61
Maluku	48.06	49.81	51.92	52.27	45.10	(...)	47.65	46.65	45.11	44.45	46.28
Maluku Utara	51.08	45.42	45.86	45.85	44.44	(...)	43.16	43.24	43.28	44.70	45.69
Papua Barat	52.71	52.96	51.02	48.36	44.09	(...)	45.65	45.72	46.26	44.20	46.27
Papua	49.10	47.79	51.75	52.14	47.32	(...)	46.64	47.02	46.84	47.94	48.01

Jaringan Syaraf Tiruan merupakan paradigma pengolahan informasi yang terinspirasi oleh sistem saraf biologis layaknya proses informasi pada otak manusia (Andrian & Putra, 2017).

Jaringan syaraf tiruan merupakan salah satu metode berbasis kecerdasan buatan, yang mampu mengidentifikasi pola, signal prosesing serta peramalan dari sistem dengan metode pembelajaran (Ihwan, 2013; Satria, 2018).

Elemen kunci dari paradigma ini adalah struktur dari sistem pengolahan informasi yang terdiri dari sejumlah besar neuron yang saling berhubungan, bekerja serentak untuk menyelesaikan masalah tertentu. Cara kerja JST seperti cara kerja manusia, yaitu belajar melalui contoh. Lapisan-lapisan penyusun JST dibagi menjadi 3, yaitu lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*) (Shaputra et al., 2021).

Backpropagation merupakan sebuah metode sistematis pada jaringan syaraf tiruan dengan menggunakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh Perceptron dengan banyak layer lapisan untuk mengubah bobot-bobot yang ada pada lapisan tersembunyinya. Algoritma *Backpropagation* merupakan generalisasi dari algoritma *least mean square* yang mengubah bobot jaringan untuk meminimalkan kesalahan antara *output* yang diinginkan dengan realisasi jaringan (Dewi & Muslikh, 2013; Kuswana et al., 2019).

Ketika pola input disajikan ke jaringan sebagai pola pelatihan, pertama-tama ia akan melakukan perjalanan ke unit lapisan tersembunyi sebelum diteruskan ke unit lapisan *output* (Windarto et al., 2017). *Output* dari jaringan saraf tiruan kemudian akan diwakili oleh unit-unit lapisan *output*. *Output* akan digunakan mundur pada layer tersembunyi dan kemudian dari layer tersembunyi ke layer input jika hasil *output* tidak seperti yang diantisipasi. Dengan mengubah bobot, jaringan saraf tiruan dilatih selama tahap ini. Fase ini, yang disebut sebagai fase pengujian (Gupta & Shreevastava, 2011), akan melibatkan pemecahan masalah jika prosedur pelatihan selesai.

3. HASIL DAN PEMBAHASAN

Dalam penelitian ini akan dilaksanakan serangkaian prediksi Data Pengeluaran Rata-rata Per Kapita untuk Makanan. Data yang digunakan sebagai *input* adalah data selama 16 tahun terakhir. Total data dari pengeluaran rata-rata akan digunakan untuk menentukan *output*. Data kemudian akan diputar dan diubah untuk menghasilkan *output* yang lebih akurat. Adapun variabel keluaran JST tentang Data Pengeluaran Rata-rata Per Kapita untuk Makanan adalah:

$$Y = \text{Data Pengeluaran Rata – rata Per Kapita untuk Makanan} \quad (1)$$

Pada titik ini, menemukan nilai untuk mengidentifikasi pola arsitektur terbaik dari serangkaian penentuan pola yang dieksekusi adalah hasil yang diinginkan. Menemukan tingkat kesalahan terkecil target adalah klasifikasi pola terbaik untuk memprediksi Data Pengeluaran Rata-rata Per Kapita untuk Makanan. Penentuan pola arsitektur optimal lebih akurat semakin kecil kesalahan minimum yang dihasilkan oleh target. Nilai kesalahan minimum terbaik, antara 0,000 dan 0,001, digunakan dalam penelitian ini (Windarto et al., 2018). Pengolahan data yang akan dilakukan adalah mengubah data tahun 2007 sampai 2022 dengan cara normalisasi data tersebut ke rentang 0 hingga 1 menggunakan rumus:

$$xi = \frac{0,8(x-a)}{b-a} + 0,1 \quad (2)$$

Dimana:

- xi = Nilai akhir normalisasi data
- x = Nilai yang akan dikonversi
- a = Nilai minimum data
- b = Nilai maksimum data

Sehingga diperoleh sebuah data baru sebagai berikut:

Tabel 2. Hasil Normalisasi Data.

Provinsi	Makanan										
	2007	2008	2009	2010	2011	(...)	2018	2019	2020	2021	2022
Aceh	0.80	0.82	0.90	0.88	0.85	(...)	0.67	0.83	0.73	0.86	0.71
Sumatera Utara	0.74	0.78	0.80	0.79	0.85	(...)	0.76	0.90	0.87	0.76	0.71
Sumatera Barat	0.77	0.83	0.84	0.86	0.86	(...)	0.59	0.73	0.73	0.72	0.64
Riau	0.70	0.76	0.82	0.83	0.77	(...)	0.49	0.57	0.51	0.49	0.54
Jambi	0.73	0.77	0.83	0.85	0.83	(...)	0.62	0.71	0.62	0.64	0.54
Sumatera Selatan	0.77	0.81	0.83	0.86	0.90	(...)	0.52	0.63	0.70	0.67	0.66
Bengkulu	0.70	0.76	0.81	0.84	0.82	(...)	0.29	0.37	0.34	0.41	0.50
Lampung	0.63	0.70	0.76	0.79	0.79	(...)	0.55	0.70	0.70	0.65	0.62
Kepulauan Bangka Belitung	0.83	0.84	0.82	0.84	0.85	(...)	0.54	0.69	0.77	0.77	0.72
Kepulauan Riau	0.67	0.73	0.78	0.82	0.78	(...)	0.50	0.42	0.47	0.42	0.46
DKI Jakarta	0.57	0.62	0.65	0.68	0.60	(...)	0.25	0.23	0.29	0.10	0.10
Jawa Barat	0.70	0.76	0.76	0.82	0.77	(...)	0.51	0.70	0.70	0.65	0.55
Jawa Tengah	0.72	0.78	0.81	0.82	0.77	(...)	0.48	0.59	0.60	0.62	0.59
DI Yogyakarta	0.63	0.67	0.72	0.71	0.74	(...)	0.10	0.10	0.10	0.13	0.24
Jawa Timur	0.70	0.75	0.80	0.83	0.79	(...)	0.49	0.52	0.56	0.60	0.58
Banten	0.65	0.70	0.73	0.72	0.75	(...)	0.45	0.63	0.69	0.60	0.62
Bali	0.65	0.72	0.71	0.73	0.66	(...)	0.26	0.33	0.35	0.20	0.22
Nusa Tenggara Barat	0.79	0.84	0.80	0.80	0.88	(...)	0.90	0.87	0.90	0.90	0.90
Nusa Tenggara Timur	0.75	0.78	0.80	0.84	0.80	(...)	0.58	0.63	0.58	0.66	0.50

Provinsi	Makanan										
	2007	2008	2009	2010	2011	(...)	2018	2019	2020	2021	2022
Kalimantan Barat	0.74	0.79	0.81	0.79	0.79	(...)	0.44	0.60	0.59	0.63	0.63
Kalimantan Tengah	0.78	0.87	0.88	0.90	0.87	(...)	0.50	0.62	0.57	0.61	0.58
Kalimantan Selatan	0.75	0.76	0.76	0.79	0.80	(...)	0.53	0.59	0.65	0.60	0.59
Kalimantan Timur	0.65	0.67	0.72	0.76	0.72	(...)	0.31	0.35	0.35	0.17	0.35
Kalimantan Utara	0.10	0.10	0.10	0.10	0.10	(...)	0.44	0.61	0.52	0.52	0.48
Sulawesi Utara	0.72	0.79	0.81	0.81	0.75	(...)	0.36	0.60	0.52	0.70	0.76
Sulawesi Tengah	0.76	0.78	0.74	0.72	0.78	(...)	0.33	0.58	0.40	0.35	0.49
Sulawesi Selatan	0.70	0.74	0.74	0.80	0.79	(...)	0.44	0.44	0.51	0.45	0.50
Sulawesi Tenggara	0.76	0.75	0.69	0.76	0.74	(...)	0.29	0.33	0.40	0.34	0.35
Gorontalo	0.68	0.78	0.83	0.82	0.79	(...)	0.34	0.24	0.13	0.32	0.21
Sulawesi Barat	0.90	0.90	0.84	0.83	0.90	(...)	0.54	0.61	0.47	0.41	0.37
Maluku	0.74	0.81	0.85	0.87	0.76	(...)	0.55	0.62	0.51	0.44	0.50
Maluku Utara	0.79	0.75	0.76	0.78	0.75	(...)	0.32	0.40	0.39	0.46	0.47
Papua Barat	0.81	0.85	0.84	0.82	0.75	(...)	0.45	0.56	0.60	0.43	0.50
Papua	0.76	0.78	0.85	0.87	0.80	(...)	0.50	0.64	0.64	0.69	0.58

Kumpulan data pengeluaran rata-rata per kapita sebulan untuk makanan di daerah Perkotaan di Indonesia yang telah dinormalisasi disajikan pada tabel 2. Rumus di atas digunakan untuk menormalisasikan data ini ke kisaran 0 hingga 1. Data tingkat upah minimum tahun 2007-2020 akan digunakan sebagai data pelatihan dan tahun 2021 akan digunakan sebagai data target pelatihan. Sedangkan data tahun 2008-2021 akan digunakan sebagai data pengujian dan data tahun 2022 akan digunakan sebagai data target pengujian. Menggunakan arsitektur optimal yang diidentifikasi dari data pelatihan, data ini digunakan untuk menguji akurasi metode Backpropagation dalam mengidentifikasi data *output* dan *input*.

Backpropagation Feedforward adalah jaringan yang digunakan untuk menentukan pengeluaran rata-rata per kapita sebulan untuk makanan di daerah perkotaan di Indonesia. Ada beberapa level dalam jaringan ini, termasuk lapisan *input*, lapisan *output*, dan beberapa lapisan tersembunyi. Lapisan tersembunyi membantu jaringan mengenali lebih banyak pola input jika dibandingkan tanpa lapisan tersembunyi (Windarto et al., 2018).


Dengan demikian sistem akan memiliki kemampuan seperti:

- Proses *input* data latih
- Proses pelatihan data dan penentuan model arsitektur
- Proses pengujian dan prediksi

Parameter yang digunakan dalam prediksi ini adalah:

- 14 neuron ($X_1, X_2, \dots, X_{14}$) pada lapisan *input*
- n neuron ($Z_1, Z_2, \dots, Z_n$) dalam lapisan *hidden*
- 1 neuron (Y_1) pada lapisan *output*

Berikut adalah contoh pembentukan parameter dengan arsitektur 5-3-1:



Gambar 1. Contoh arsitektur jaringan.

Fungsi pada Jaringan Syaraf Tiruan ini akan dibangun dengan menggunakan fungsi aktivasi Sigmoid. Fungsi aktivasi dalam Jaringan Saraf Tiruan dipakai untuk proses perhitungan terhadap nilai aktual *output* pada *hidden layer* dan menghitung nilai aktual *output* pada *output layer*.

Pelatihan dan pengujian dilakukan terhadap 4 buah arsitektur yakni: 14-5-1; 14-6-1; 14-7-1 dan 14-8-1, kemudian dipilihlah arsitektur 14-5-1 yang merupakan data terbaik dengan hasil akurasi prediksi sebesar 94%. Berikut adalah hasil perbandingan tiap arsitektur:

Tabel 3. Hasil Normalisasi Data.

No	Arsitektur	Conjugate Gradient Backpropagation with Fletcher Revees Restarts		
		Iterasi	MSE	Akurasi
1	14-5-1	355	0.00099964	91%
2	14-6-1	145	0.00099417	59%
3	14-7-1	312	0.00099027	79%
4	14-8-1	288	0.00099188	74%

Berikut adalah parameter yang digunakan di dalam aplikasi Matlab dalam penentuan model arsitektur yang dapat dilihat pada Gambar 2 :

```
net = newff(minmax(p),[hidden,output],{'tansig','logsig'},'traincgf');

net.IW{1,1}
net.LW{2,1}
net.b{1}
net.b{2}


net.trainParam.epochs = 100000;
net.trainParam.show = 25;
net.trainParam.showCommandLine = 0;
net.trainParam.showWindow = 1;
net.trainParam.goal = 0.001;
net.trainParam.time = inf;
net.trainParam.min_grad = 1e-6;
net.trainParam.max_fail = 5;
net.trainParam.searchFcn = 'srchcha'

net = train(net,p,t)

[a,Pf,Af,e,perf] = sim(net,p1,[],[],t1)
```

Gambar 2. Parameter untuk aplikasi Matlab

Menggunakan parameter tersebut maka proses penentuan model arsitektur terbaik Backpropagation dilakukan. Gambar berikut adalah hasil pelatihan dari arsitektur 14-5-1 dengan menggunakan aplikasi Matlab.



Gambar 3. Hasil pelatihan dengan Matlab

Gambar 3 mengilustrasikan cara mencapai hasil yang diinginkan adalah dengan *Epoch training* sebesar 355 dan *Mean Square Error* (MSE) sebesar 0,00099964. Hasil pengujian terhadap arsitektur 14-5-1 ditunjukkan pada tabel di bawah ini.

Tabel 4. Data hasil pengujian

Training				Testing				Hasil
Fletcher Reeves				Fletcher Reeves				
Target	Output	Error	SSE	Target	Output	Error	SSE	
0.8592	0.8252	0.0340	0.0012	0.7051	0.6883	0.0168	0.0003	1
0.7616	0.7632	-0.0016	0.0000	0.7087	0.5273	0.1814	0.0329	1
0.7250	0.7421	-0.0171	0.0003	0.6362	0.5409	0.0953	0.0091	1
0.4929	0.5701	-0.0772	0.0060	0.5443	0.3129	0.2314	0.0536	1
0.6374	0.6896	-0.0522	0.0027	0.5405	0.5298	0.0107	0.0001	1
0.6738	0.6720	0.0018	0.0000	0.6550	0.4515	0.2035	0.0414	1
0.4121	0.3675	0.0446	0.0020	0.5038	0.3282	0.1756	0.0308	1
0.6456	0.6281	0.0175	0.0003	0.6191	0.3725	0.2466	0.0608	1
0.7668	0.7753	-0.0085	0.0001	0.7159	0.7208	-0.0049	0.0000	0
0.4205	0.3878	0.0327	0.0011	0.4572	0.2503	0.2069	0.0428	1
0.1000	0.1058	-0.0058	0.0000	0.1000	0.0459	0.0541	0.0029	1
0.6491	0.6285	0.0206	0.0004	0.5499	0.4283	0.1216	0.0148	1
0.6175	0.6113	0.0062	0.0000	0.5903	0.4719	0.1184	0.0140	1
0.1317	0.1302	0.0015	0.0000	0.2391	0.0767	0.1624	0.0264	1
0.6011	0.5759	0.0252	0.0006	0.5800	0.4602	0.1198	0.0144	1
0.5997	0.5683	0.0314	0.0010	0.6192	0.4436	0.1756	0.0308	1
0.1976	0.1931	0.0045	0.0000	0.2151	0.0889	0.1262	0.0159	1
0.9000	0.8620	0.0380	0.0014	0.9000	0.7100	0.1900	0.0361	1
0.6590	0.6125	0.0465	0.0022	0.4972	0.4459	0.0513	0.0026	1
0.6335	0.6364	-0.0029	0.0000	0.6259	0.4060	0.2199	0.0484	1
0.6054	0.6496	-0.0442	0.0020	0.5847	0.4401	0.1446	0.0209	1

Training				Testing				Hasil
Fletcher Reeves				Fletcher Reeves				
Target	Output	Error	SSE	Target	Output	Error	SSE	
0.6042	0.6642	-0.0600	0.0036	0.5880	0.3818	0.2062	0.0425	1
0.1745	0.2439	-0.0694	0.0048	0.3528	0.1364	0.2164	0.0468	1
0.5155	0.5242	-0.0087	0.0001	0.4846	0.5599	-0.0753	0.0057	0
0.6951	0.6830	0.0121	0.0001	0.7551	0.3428	0.4123	0.1700	1
0.3489	0.3383	0.0106	0.0001	0.4899	0.2087	0.2812	0.0791	1
0.4452	0.4657	-0.0205	0.0004	0.5032	0.3624	0.1408	0.0198	1
0.3369	0.3494	-0.0125	0.0002	0.3499	0.1981	0.1518	0.0230	1
0.3166	0.2900	0.0266	0.0007	0.2071	0.1790	0.0281	0.0008	1
0.4114	0.4286	-0.0172	0.0003	0.3741	0.3770	-0.0029	0.0000	0
0.4446	0.4484	-0.0038	0.0000	0.4992	0.2921	0.2071	0.0429	1
0.4621	0.4177	0.0444	0.0020	0.4713	0.2540	0.2173	0.0472	1
0.4267	0.4345	-0.0078	0.0001	0.4989	0.2631	0.2358	0.0556	1
0.6894	0.6710	0.0184	0.0003	0.5802	0.5594	0.0208	0.0004	1
Total							1.0330	91%
MSE							0.0313	

Keterangan:

Output = Diperoleh dari hasil pengujian Matlab

Error = Diperoleh dari hasil pengujian Matlab

SSE = $Error^2$

Total = Total nilai *SSE*

MSE = Total *SSE* / Jumlah data

Hasil = "0" Jika $Output > Target$

= "1" jika $Output \leq Target$

Berdasarkan tabel 4 diperjelas jika tingkat akurasi yang di dapatkan pada pengujian arsitektur 14-5-1 yakni sebesar 91%.

4. KESIMPULAN

Dari penelitian di atas maka ditetapkan beberapa hal antara lain:

- JST Backpropagation dapat diimplementasikan untuk memprediksi pengeluaran perkapita.
- Menambah jumlah *hidden layer* terkadang bukanlah opsi yang tepat demi mencapai nilai tertinggi.
- Setelah dilakukan pelatihan dan pengujian menggunakan *tool* Matlab maka diperoleh hasil model arsitektur terbaik yakni 14-5-1 dengan *Mean Square Error* (MSE) pengujian sebesar 0,00099964 dan jumlah *epoch* sebesar 355.

ACKNOWLEDGEMENTS

Terima kasih disampaikan kepada pihak-pihak yang telah mendukung terlaksananya penelitian ini

REFERENCES

- Andrian, Y., & Ningsih, E. (2014). Prediksi Curah Hujan Di Kota Medan Menggunakan. *Seminar Nasional Informatika*, 184–189.
- Andrian, Y., & Putra, P. H. (2017). Analisis Penambahan Momentum Pada Proses Prediksi Curah Hujan Kota Medan

- Menggunakan Metode. *Seminar Nasional Informatika*, 165–172.
- Aulia, R. (2018). PENERAPAN METODE BACKPROPAGATION UNTUK MEMPREDIKSI JUMLAH KUNJUNGAN WISATAWAN BERDASARKAN TINGKAT HUNIAN HOTEL. *JURTEKSI*, 4(2), 115–122.
- Dewi, C., & Muslikh, M. (2013). Perbandingan Akurasi Backpropagation Neural Network dan ANFIS Untuk Memprediksi Cuaca. *Journal of Scientific Modeling & Computation*, 1(1), 7–13.
- Gupta, A., & Shreevastava, M. (2011). Medical Diagnosis using Back propagation Algorithm. *International Journal of Emerging Technology and Advanced Engineering*, 1(1), 55–58.
- Hansun, S. (2013). Peramalan Data IHSG Menggunakan Metode Backpropagation. *Jurnal ULTIMATICS*, 5(1), 26–30.
- Ihwan, A. (2013). Metode Jaringan Saraf Tiruan Propagasi Balik Untuk Estimasi Curah Hujan Bulanan di Ketapang Kalimantan Barat. *Prosiding Semirata*, 1(1), 243–247.
- Kuswana, R. U., Abdillah, G., & ... (2019). Prediksi Realisasi Penerimaan Pajak Bumi dan Bangunan di Pemerintah Kabupaten Bandung Barat Menggunakan Jaringan Syaraf Tiruan Backpropagation. ... *Nasional Sains Dan ...*, 580–585.
- Saragih, J. R., Saragih, M. B. S., & Wanto, A. (2018). Analisis Algoritma Backpropagation Dalam Prediksi Nilai Ekspor (Juta Usd). *Jurnal Pendidikan Teknologi Dan Kejuruan*, 15(2), 254–264.
- Satria, B. (2018). Prediksi Volume Penggunaan Air PDAM Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 2(3), 674–684.
- Shaputra, E., Ginting, B. S., & Nurhayati. (2021). Prediksi Pendapatan Asli Daerah (Pad) Kabupaten Langkat Menggunakan Metode Backpropagation. *JTIK (Jurnal Teknik ...)*, 5(1), 69–75.
- Thoriq, M. (2022). Peramalan Jumlah Permintaan Produksi Menggunakan Jaringan Saraf Tiruan Algoritma Backpropagation. *Jurnal Informasi Dan Teknologi*, 1(2), 27–32.
- Wanto, A., & Windarto, A. P. (2017). Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation. *Jurnal & Penelitian Teknik Informatika*, 2(2).
- Windarto, A. P., Lubis, M. R., & Solikhun. (2018). Model Arsitektur Neural Network Dengan Backpropogation Pada Prediksi Total Laba. *Kumpulan Jurnal Ilmu Komputer*, 05(02), 147–158. www.ojk.go.id
- Windarto, A. P., Solikhun, S., Handrizal, H., & Fauzan, M. (2017). Jaringan Saraf Tiruan Dalam Memprediksi Sukuk Negara Ritel Berdasarkan Kelompok Profesi Dengan Backpropogation Dalam Mendorong Laju Pertumbuhan Ekonomi. *Klik - Kumpulan Jurnal Ilmu Komputer*, 4(2), 184.