



Optimalisasi Parameter dengan *Cross Validation* dan *Neural Back-propagation* Pada Model Prediksi Pertumbuhan Industri Mikro dan Kecil

Agus Perdana Windarto^{a,b*}, Sarjon Defit^b, Anjar Wanto^{a,b}

^a STIKOM Tunas Bangsa, Pematangsiantar
^b Universitas Putra Indonesia YPTK, Padang, Indonesia

Naskah Diterima : 17 Maret 2021; Diterima Publikasi : 19 Mei 2021

DOI: 10.21456/vol11iss1pp34-42

Abstract

It is important for us to predict what will happen in future and to reduce uncertainty. Various analyzes are therefore necessary in order to optimize or improve the prediction results by several methods. The objective of this research is to analyze predictive results by optimizing the training and testing by means of cross validating parameters on the growth of micro and small-scale production in Indonesia through the exactness of the return-propagative method. The method of reproduction is used. These results are compared with results of backpropagation during training and testing without optimisation of the same architectural model. The dataset is based on the growth in production in micro and small businesses by province from the Central Statistical Agency(BPS). There were 34 records in which data from 2015-2019 for growth of production were collected. The results with optimisation have surpassed without optimisation the back propagation model by looking at RMSE, in which the best RMSE in the 3-2-1 architectural model was obtained and the side type is mixed sampling. The obtained RMSE value is 0.1526, or a difference between the best background architectural model, 3-2-1 and 0.0034. (0.157). The results of this model were 94 percent.

Keywords: Optimization; Industrial production growth; Back-propagation; Cross validation; Optimize Parameters.

Abstrak

Pentingnya melakukan prediksi adalah untuk mengurangi ketidakpastian dan membuat perkiraan lebih baik dari apa yang akan terjadi di masa depan. Oleh karena itu dibutuhkan berbagai analisa untuk meningkatkan hasil prediksi dengan melakukan optimasi atau perbaikan dari sejumlah metode. Tujuan dari penelitian untuk menganalisa hasil prediksi melalui akurasi dari metode *back-propagation* dengan melakukan optimasi pada pelatihan dan pengujian dengan *optimize parameters* dengan *cross validation* pada pertumbuhan produksi Industri mikro dan kecil di Indonesia. Metode yang digunakan adalah *back-propagation*. Hasil tersebut dibandingkan dengan hasil *back-propagation* tanpa menggunakan optimasi dengan model arsitektur yang sama pada saat pelatihan dan pengujian. Dataset bersumber dari Badan Pusat Statistik (BPS) tentang pertumbuhan produksi pada usaha mikro dan kecil berdasarkan provinsi. Data terdiri dari 34 record dimana data pertumbuhan produksi diambil dari tahun 2015 – 2019. Hasil menggunakan optimasi mengungguli model *back-propagation* tanpa optimasi dengan melihat RMSE dimana diperoleh RMSE terbaik pada model arsitektur 3-2-1 dengan tipe samping adalah *shuffled sampling*. Nilai RMSE yang diperoleh adalah 0.1526 atau selisih 0,0034 dari model arsitektur terbaik *back-propagation* tanpa optimasi yakni 3-2-1 (0.157). Dengan model tersebut diperoleh hasil prediksi mencapai 94 persen.

Keywords: Optimasi; Pertumbuhan Produksi Industri; *Back-Propagation*; *Cross Validation*; *Optimize Parameters*

1. Pendahuluan

Masyarakat seringkali menghadapi berbagai kesulitan, sehingga menuntut orang untuk berpikir dan menemukan hal-hal baru untuk menyelesaikan masalahnya. Bersamaan dengan perkembangan sains dan teknologi, ada banyak cara di mana objek dapat dianalisis, diprediksi, diklasifikasikan dan divisualisasikan sehingga bermanfaat bagi aktivitas manusia (Lesnussa *et al.*, 2018). Prediksi merupakan

proses estimasi berdasarkan informasi masa lalu dan masa kini, yang kemungkinan besar akan terjadi di masa mendatang (Wanto, 2018). Dalam kehidupan manusia, prediksi sangatlah penting untuk meminimalisir dampak suatu masalah dimasa yang akan datang (Indrayati Sijabat *et al.*, 2020). Jaringan Saraf Tiruan (JST) merupakan sebuah jaringan yang dirancang menyerupai otak manusia (Febriadi *et al.*, 2018; Windarto *et al.*, 2020) yang bertujuan untuk melaksanakan suatu tugas tertentu (Indrayati Sijabat

*) Penulis korespondensi: agus.perdana@amiktunasbangsa.ac.id

et al., 2020). Salah satu metode *problem solving* dari JST adalah menyelesaikan kasus prediksi dengan beberapa metode seperti *perceptron*, *back-propagation* dan *fuzzy* (Windarto *et al.*, 2018). Dalam kasus prediksi metode yang sering digunakan adalah *back-propagation* karena kemampuannya dalam memecahkan masalah dunia nyata dengan mengembangkan metode terlatih yang menunjukkan kinerja yang baik dalam skala yang luas dan mampu mengatasi pengenalan pola yang kompleks (Nikentari *et al.*, 2018). Namun metode *back-propagation* memiliki beberapa kelemahan antara lain laju konvergensi yang lambat, sulit mengoptimalkan model arsitektur terbaik karena harus melakukan serangkaian uji coba, dan terjebak dalam minimum lokal, hal ini dapat menyebabkan kegagalan dalam mencari solusi yang optimal untuk pemilihan fitur pada bobot atribut yang digunakan (Budiharjo *et al.*, 2018a, 2018b). Sehingga banyak penelitian terkait optimasi yang dilakukan untuk mengatasi kelemahan tersebut.

Seperti penelitian (Kurniawan *et al.*, 2019) tentang optimasi inisialisasi bobot nguyen widrow dengan metode *back-propagation* dalam kasus peramalan harga saham. Hasil pengujian sangat efektif dengan arsitektur 2-10-1 untuk peramalan harga *close* saham AALI.JK dan arsitektur 2-20-1 untuk peramalan harga *close* saham BBCA.JK. Kemudian penelitian (Nikentari *et al.*, 2018) tentang optimasi *Particle Swarm Optimization* dengan *back-propagation* pada prediksi tinggi pasang surut air laut. Hasil pengujian menunjukkan akurasi prediksi adalah 91.56 dengan lr: 0.9, *swarm*: 90, dan iterasi 30 kali. Selanjutnya yang dilakukan (Wanto, 2018) tentang optimasi *back-propagation* menggunakan *conjugate gradient beale-powell restarts* pada data Indeks Harga Konsumen (IHK) kelompok kesehatan. Hasil pengujian menunjukkan durasi waktu pelatihan menggunakan optimasi lebih cepat dibanding model standart *back-propagation*.

Berdasarkan penelitian-penelitian sebelumnya, tujuan dari penelitian untuk melakukan optimasi pada pelatihan dan pengujian dengan *optimize parameters* dengan *cross validation* untuk menghasilkan nilai akurasi yang baik mengingat penelitian terkait optimasi menghasilkan pengetahuan yang lebih baik daripada menggunakan model *back-propagation* standar (tanpa optimasi). Hasil dari makalah yang diperoleh tersebut dibandingkan dengan hasil *back-propagation* tanpa menggunakan optimasi dengan model arsitektur yang sama pada saat pelatihan dan pengujian. Kasus yang diangkat adalah pertumbuhan produksi Industri mikro dan kecil di Indonesia. Diharapkan hasil dari penelitian dapat dijadikan rujukan dalam melakukan analisa hasil prediksi melalui akurasi dari metode *back-propagation* dengan melakukan optimasi pada pelatihan dan pengujian dengan *optimize parameters* dengan *cross*

validation pada pertumbuhan produksi Industri mikro dan kecil di Indonesia.

2. Kerangka Teori

2.1. Optimalisasi parameter

Optimasi merupakan suatu usaha atau kegiatan untuk mencapai hasil yang sebaik mungkin. Proses optimasi di salah satu algoritma pembelajaran memastikan bahwa hasil yang dicapai berbeda (Wanto, 2018).

2.2. Cross Validation

Merupakan langkah di mana keakuratan prediksi dapat divalidasi. Rumus K-Fold *Cross Validation* adalah sebagai berikut (Prasaty *et al.*, 2020):

$$\text{akurasi} = (\sum \text{klasifikasi benar} / \sum \text{data uji}) \times 100\% \quad (1)$$

Dimana pada variabel akurasi merupakan hasil akurasi; klasifikasi benar merupakan jumlah prediksi benar dan data uji merupakan jumlah data yang dilakukan pengujian.

2.3. Neural Back-propagation

Metode *Neural Back-propagation* merupakan Metode yang terdapat dalam jaringan saraf tiruan didasarkan pada dan terinspirasi oleh sistem saraf manusia di mana sistem ini berkembang melalui pembelajaran dan contoh (Kurniawan *et al.*, 2019).

2.4. Pertumbuhan Ekonomi di Indonesia

Pertumbuhan ekonomi merupakan sebuah proses peningkatan *output* dari waktu ke waktu yang menjadi indikator penting mengukur keberhasilan pembangunan suatu negara (Ma'ruf & Wihastuti, 2008). Oleh karena itu identifikasi berbagai macam faktor yang mempengaruhinya termasuk peran pemerintah menjadi menarik untuk dikaji lebih dalam (Pambudi & Miyasto, 2013).

3. Metode

Data yang digunakan adalah Data yang bersumber dari Badan Pusat Statistik (BPS) tentang pertumbuhan produksi pada usaha mikro dan kecil berdasarkan provinsi. Data terdiri dari 34 record dimana data pertumbuhan produksi diambil dari tahun 2015 – 2019. Data dapat diakses pada url: <https://www.bps.go.id/indicator/170/404/1/pertumbuhan-produksi-triwulan-q-to-q-menurut-provinsi.html>.

Data tersebut terdiri dari pertumbuhan produksi triwulan Q to Q menurut provinsi (%) berdasarkan provinsi. Data tersebut ditransformasi ke biner (0-1) karena menggunakan fungsi aktivasi Sigmoid Biner. Sehingga hasil data berkisar diantara 0-1. Adapun formula yang digunakan melakukan transformasi adalah $x_1 = (0.8(x-a)/b-a) + 0.1$ (2)

Adapun dataset yang digunakan seperti pada Tabel 1 dan 2.

Tabel 1. Dataset penelitian

Provinsi	Pertumbuhan Produksi Triwulan Q to Q menurut provinsi (%)				
	2015	2016	2017	2018	2019
Aceh	3,36	2,42	20,99	8,14	12,19
Sumatera Utara	6,06	10,75	0,66	7,9	9,01
Sumatera Barat	1,92	3,98	-2,58	2,33	6,75
Riau	-3,14	-2,09	11,15	9,23	8,02
Jambi	9,21	5,35	13,82	6,56	3,13
Sumatera Selatan	-7,81	8,28	5,21	0,99	10,84
Bengkulu	8,11	7,78	10,59	11,67	2,14
Lampung	9,06	6,76	1,26	3,08	3,59
Kep. Bangka Belitung	-4,97	-8,6	8,27	2,48	6,92
Kep. Riau	12,85	0,76	9,65	20,31	21,04
DKI Jakarta	11,43	11,69	16,95	21,4	8,57
Jawa Barat	2,48	-1,55	1,08	1,4	8,48
Jawa Tengah	6,57	2,6	-3,35	2,88	5,13
DI Yogyakarta	3,83	6,35	15,01	7,15	1,37
Jawa Timur	5,79	2,53	3,12	10,88	7,53
Banten	2,3	10,64	20,87	6,7	8,06
Bali	13,8	11,56	4,11	13,23	11,86
Nusa Tenggara Barat	-7,27	-3,98	-0,07	14,37	8,15
Nusa Tenggara Timur	6,03	15,99	25,6	28,2	23,76
Kalimantan Barat	5,35	1,83	3,98	7,54	4,13
Kalimantan Tengah	10,77	2,78	20,8	3,89	7,4
Kalimantan Selatan	8,67	14,61	17,19	22,94	9,7
Kalimantan Timur	2,33	17,33	7,58	43,3	11,49
Kalimantan Utara	9,87	29,81	26,87	8,89	5,1
Sulawesi Utara	4,31	1,64	4,99	9,63	7,93
Sulawesi Tengah	6,56	14,69	5,18	17,12	17,26
Sulawesi Selatan	2,12	4,08	-0,01	13,22	16,62
Sulawesi Tenggara	0,37	9,58	18,94	33,31	20,15
Gorontalo	14,9	15,63	15,63	42,65	31,24
Sulawesi Barat	14,91	20,39	20,34	7,77	28,3
Maluku	20,35	23,55	17,61	16,86	13,66
Maluku Utara	14,87	24,19	21,86	24,01	-3,54
Papua Barat	16,44	9,77	4,31	0,76	21,28
Papua	8,03	15,79	19,13	-3,98	7,65

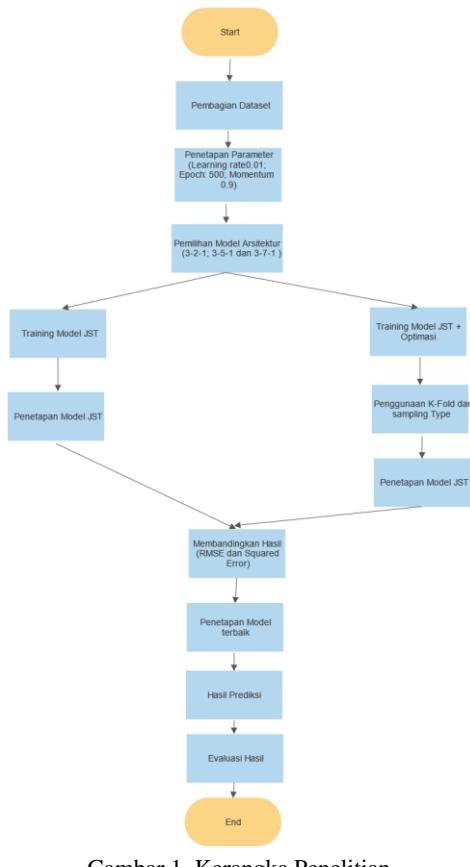
Sumber: Badan Pusat Statistik

Tabel 2. Dataset hasil transformasi

Provinsi	2015	2016	2017	2018	2019
Aceh	0,284355	0,269865	0,556108	0,358035	0,420462
Sumatera Utara	0,325973	0,398266	0,242736	0,354335	0,371445
Sumatera Barat	0,262158	0,293911	0,192794	0,268478	0,336609
Riau	0,184162	0,200347	0,404432	0,374836	0,356185
Jambi	0,374528	0,315029	0,445588	0,33368	0,280809
Sumatera Selatan	0,112177	0,360193	0,312871	0,247823	0,399653
Bengkulu	0,357572	0,352486	0,3958	0,412447	0,265549
Lampung	0,372216	0,336763	0,251985	0,280039	0,2879
Kep. Bangka Belitung	0,155954	0,1	0,360039	0,27079	0,339229
Kep. Riau	0,430636	0,244277	0,38131	0,545626	0,556879
DKI Jakarta	0,408748	0,412755	0,493834	0,562428	0,364663
Jawa Barat	0,27079	0,208671	0,24921	0,254143	0,363276
Jawa Tengah	0,333834	0,27264	0,180925	0,276956	0,311638
DI Yogyakarta	0,291599	0,330443	0,463931	0,342775	0,25368
Jawa Timur	0,321811	0,271561	0,280655	0,40027	0,348632
Banten	0,268015	0,39657	0,554258	0,335838	0,356802
Bali	0,445279	0,410751	0,295915	0,436493	0,415376
Nusa Tenggara Barat	0,120501	0,171214	0,231484	0,454066	0,358189
Nusa Tenggara Timur	0,325511	0,479037	0,627168	0,667245	0,598805
Kalimantan Barat	0,315029	0,260771	0,293911	0,348786	0,296224
Kalimantan Tengah	0,398574	0,275414	0,553179	0,292524	0,346628
Kalimantan Selatan	0,366204	0,457765	0,497534	0,586166	0,382081
Kalimantan Timur	0,268478	0,499692	0,349403	0,9	0,409672
Kalimantan Utara	0,384701	0,692062	0,646744	0,369595	0,311175
Sulawesi Utara	0,298998	0,257842	0,30948	0,381002	0,354798
Sulawesi Tengah	0,33368	0,458998	0,312408	0,496455	0,498613
Sulawesi Selatan	0,265241	0,295453	0,232408	0,436339	0,488748
Sulawesi Tenggara	0,238266	0,380231	0,524509	0,746012	0,54316
Gorontalo	0,462235	0,473487	0,473487	0,889981	0,714104
Sulawesi Barat	0,462389	0,546859	0,546089	0,352331	0,668786
Maluku	0,546243	0,595568	0,504008	0,492447	0,443121
Maluku Utara	0,461773	0,605434	0,569518	0,602659	0,177996
Papua Barat	0,485973	0,38316	0,298998	0,244277	0,560578
Papua	0,356339	0,475954	0,527437	0,171214	0,350482

Sumber: Data olahan

Pada Tabel 2 hasil transformasi data menggunakan formula (2) dimana nilai hasil transformasi berkisar 0-1 karena fungsi aktivasi yang digunakan *Sigmoid Biner*.



Pada Gambar 1 dijelaskan proses prediksi dilakukan dengan melakukan perbandingan hasil terhadap model optimasi *back-pro* dan *back-pro* tanpa optimasi. Diawali dengan pembagian dataset sebagai data pelatihan dan pengujian (Tabel 2), dilanjutkan dengan penetapan parameter dan pemilihan secara acak model arsitektur yang akan digunakan. Selanjutnya proses dilakukan dengan menunjukkan hasil dari kedua model (model optimasi *back-pro* dan *back-pro* tanpa optimasi). Hasil dari kedua model selanjutnya dibandingkan dengan melihat nilai RMSE dan *Squared Error* sebelum dilakukan penetapan model terbaik yang nanti digunakan untuk melakukan prediksi. Hasil dari prediksi dengan model arsitektur terbaik akan dievaluasi dengan melihat nilai akurasi. Hasil dari evaluasi akan dijadikan pertimbangan untuk pengembangan penelitian kedepan.

4. Hasil dan Pembahasan

4.1. Hasil pengujian menggunakan Software

Dataset pada tabel 2 dibagi menjadi dua bagian yakni data pelatihan dan data pengujian. Pengolahan data dilakukan dengan bantuan aplikasi software RapidMiner. Pada data pelatihan, data yang digunakan adalah pertumbuhan produksi 2016-2018. seperti yang ditunjukkan Tabel 3 berikut.

a) Data Pelatihan (*training*)

Input (X): X1 s/d X3 (data tahun pertumbuhan produksi (2015-2017))

Output (Y): Y (data tahun pertumbuhan produksi) (2018)

Tabel 3. Dataset Pelatihan

Provinsi	X1=2015	X2=2016	X3=2017	Y=2018
Aceh	0,28435	0,26987	0,55611	0,35803
Sumatera Utara	0,32597	0,39827	0,24274	0,35434
Sumatera Barat	0,26216	0,29391	0,19279	0,26848
Riau	0,18416	0,20035	0,40443	0,37484
Jambi	0,37453	0,31503	0,44559	0,33368
Sumatera Selatan	0,11218	0,36019	0,31287	0,24782
Bengkulu	0,35757	0,35249	0,39580	0,41245
Lampung	0,37222	0,33676	0,25198	0,28004
Kep. Bangka Belitung	0,15595	0,10000	0,36004	0,27079
Kep. Riau	0,43064	0,24428	0,38131	0,54563
DKI Jakarta	0,40875	0,41276	0,49383	0,56243
Jawa Barat	0,27079	0,20867	0,24921	0,25414
Jawa Tengah	0,33383	0,27264	0,18092	0,27696
DI Yogyakarta	0,29160	0,33044	0,46393	0,34277
Jawa Timur	0,32181	0,27156	0,28066	0,40027
Banten	0,26802	0,39657	0,55426	0,33584
Bali	0,44528	0,41075	0,29592	0,43649
Nusa Tenggara Barat	0,12050	0,17121	0,23148	0,45407
Nusa Tenggara Timur	0,32551	0,47904	0,62717	0,66724
Kalimantan Barat	0,31503	0,26077	0,29391	0,34879
Kalimantan Tengah	0,39857	0,27541	0,55318	0,29252
Kalimantan Selatan	0,36620	0,45776	0,49753	0,58617
Kalimantan Timur	0,26848	0,49969	0,34940	0,90000
Kalimantan Utara	0,38470	0,69206	0,64674	0,36960
Sulawesi Utara	0,29900	0,25784	0,30948	0,38100
Sulawesi Tengah	0,33368	0,45900	0,31241	0,49645
Sulawesi Selatan	0,26524	0,29545	0,23241	0,43634
Sulawesi Tenggara	0,23827	0,38023	0,52451	0,71410
Gorontalo	0,46224	0,47349	0,47349	0,88998
Sulawesi Barat	0,46239	0,54686	0,54609	0,35233
Maluku	0,54624	0,59557	0,50401	0,49245
Maluku Utara	0,46177	0,60543	0,56952	0,60266
Papua Barat	0,48597	0,38316	0,29900	0,24428
Papua	0,35634	0,47595	0,52744	0,17121

Sumber: Data olahan

Pada data pengujian, data yang digunakan adalah pertumbuhan produksi 2017-2019. seperti yang ditunjukkan tabel 4 berikut.

b) Data Pelatihan (*training*)

Input (X): X1 s/d X3 (data tahun pertumbuhan produksi (2016-2018))

Output (Y): Y (data tahun pertumbuhan produksi) (2019)

Tabel 4. Dataset Pengujian

Provinsi	X1=2016	X2=2017	X3=2018	Y=2019
Aceh	0,26987	0,55611	0,35803	0,42046
Sumatera Utara	0,39827	0,24274	0,35434	0,37145
Sumatera Barat	0,29391	0,19279	0,26848	0,33661
Riau	0,20035	0,40443	0,37484	0,35618
Jambi	0,31503	0,44559	0,33368	0,28081
Sumatera Selatan	0,36019	0,31287	0,24782	0,39965
Bengkulu	0,35249	0,39580	0,41245	0,26555
Lampung	0,33676	0,25198	0,28004	0,28790
Kep. Bangka Belitung	0,10000	0,36004	0,27079	0,33923
Kep. Riau	0,24428	0,38131	0,54563	0,55688
DKI Jakarta	0,41276	0,49383	0,56243	0,36466
Jawa Barat	0,20867	0,24921	0,25414	0,36328
Jawa Tengah	0,27264	0,18092	0,27696	0,31164
DI Yogyakarta	0,33044	0,46393	0,34277	0,25368
Jawa Timur	0,27156	0,28066	0,40027	0,34863
Banten	0,39657	0,55426	0,33584	0,35680
Bali	0,41075	0,29592	0,43649	0,41538
Nusa Tenggara Barat	0,17121	0,23148	0,45407	0,35819
Nusa Tenggara Timur	0,47904	0,62717	0,66724	0,59881
Kalimantan Barat	0,26077	0,29391	0,34879	0,29622
Kalimantan Tengah	0,27541	0,55318	0,29252	0,34663
Kalimantan Selatan	0,45776	0,49753	0,58617	0,38208
Kalimantan Timur	0,49969	0,34940	0,90000	0,40967
Kalimantan Utara	0,69206	0,64674	0,36960	0,31118
Sulawesi Utara	0,25784	0,30948	0,38100	0,35480

Provinsi	X1=2016	X2=2017	X3=2018	Y=2019
Sulawesi Tengah	0,45900	0,31241	0,49645	0,49861
Sulawesi Selatan	0,29545	0,23241	0,43634	0,48875
Sulawesi Tenggara	0,38023	0,52451	0,74601	0,54316
Gorontalo	0,47349	0,47349	0,88998	0,71410
Sulawesi Barat	0,54686	0,54609	0,35233	0,66879
Maluku	0,59557	0,50401	0,49245	0,44312
Maluku Utara	0,60543	0,56952	0,60266	0,17800
Papua Barat	0,38316	0,29900	0,24428	0,56058
Papua	0,47595	0,52744	0,17121	0,35048

Sumber: Data olahan

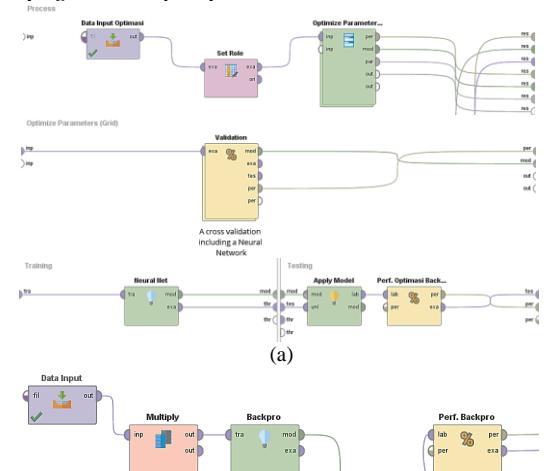
Model arsitektur yang dibuat untuk dilatih dan diuji adalah 3-2-1; 3-5-1 dan 3-7-1 dengan parameter yang digunakan:

Learning rate : 0.01

Epoch : 500

Momentum : 0.9

Pada optimasi *Optimize Parameters* dengan *Cross Validation* menggunakan k-fold: 2, 3, 4, 5, 6, 7, 8, 9, 10 dengan sampling tipe adalah *linear sampling* dan *shuffled sampling*. Berikut rancangan model optimasi *optimize parameters* dengan *cross validation* pada *Back-propagation* dan *Back-propagation* tanpa optimasi.



Sumber: Data olahan

(b)

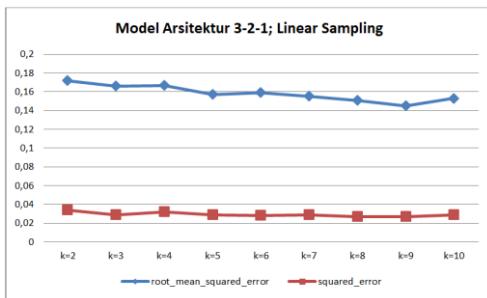
Gambar 2. Model optimasi *back-pro* dan tanpa optimasi dengan bantuan software RapidMiner

Pada Gambar 2(a) merupakan analisa menggunakan bantuan RapidMiner pada model optimasi *back-pro* dimana dalam model ini menggunakan *optimize parameters* dengan *cross validation*. Sedangkan Gambar 2(b) merupakan analisa menggunakan bantuan RapidMiner pada model *back-pro* tanpa optimasi. Berikut hasil pelatihan dan pengujian menggunakan optimasi *optimize parameters* dengan *cross validation* pada setiap model arsitektur pada Tabel 5.

Tabel 5. Hasil pengujian model arsitektur 3-2-1; *linear sampling*

K-fold	Sampling Type	Model Arsitektur	RMSE	Squared Error
k=2	Linear Sampling	3-2-1	0,172	0,034
k=3	Linear Sampling	3-2-1	0,166	0,029
k=4	Linear Sampling	3-2-1	0,167	0,032
k=5	Linear Sampling	3-2-1	0,157	0,029
k=6	Linear Sampling	3-2-1	0,159	0,028
k=7	Linear Sampling	3-2-1	0,155	0,029
k=8	Linear Sampling	3-2-1	0,151	0,027
k=9	Linear Sampling	3-2-1	0,145	0,027
k=10	Linear Sampling	3-2-1	0,153	0,029
Rata-rata			0,1583	0,0293

Sumber: Data olahan



Sumber: Data olahan

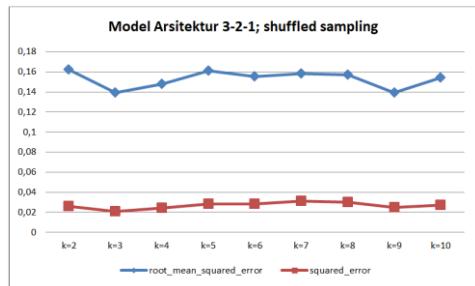
Gambar 3. Grafik pengujian model arsitektur 3-2-1; *linear Sampling*

Pada Tabel 5 dijelaskan model arsitektur 3-2-1; *sampling type= linear samping* menggunakan *cross validation* dengan k-fold (2 sampai 10) diperoleh hasil RMSE dan SE yang berbeda. Hasil RMSE terkecil terdapat pada k-fold=9 dengan rata-rata keseluruhan RMSE dan SE adalah 0,1583 dan 0,0293.

Tabel 6. Hasil pengujian model arsitektur 3-2-1; *shuffled sampling*

K-fold	Sampling Type	Model Arsitektur	RMSE	Squared Error
k=2	shuffled sampling	3-2-1	0,162	0,026
k=3	shuffled sampling	3-2-1	0,139	0,021
k=4	shuffled sampling	3-2-1	0,148	0,024
k=5	shuffled sampling	3-2-1	0,161	0,028
k=6	shuffled sampling	3-2-1	0,155	0,028
k=7	shuffled sampling	3-2-1	0,158	0,031
k=8	shuffled sampling	3-2-1	0,157	0,03
k=9	shuffled sampling	3-2-1	0,139	0,025
k=10	shuffled sampling	3-2-1	0,154	0,027
Rata-rata			0,1526	0,0267

Sumber: Data olahan



Sumber: Data olahan

Gambar 4. Grafik pengujian model arsitektur 3-2-1; *shuffled sampling*

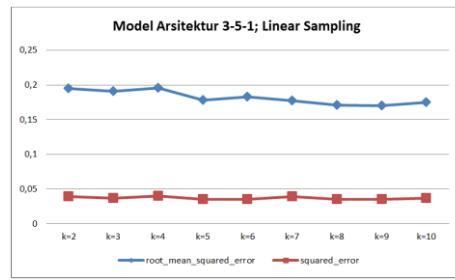
Pada Tabel 6 dijelaskan model arsitektur 3-2-1; *sampling type= shuffled sampling* menggunakan

cross validation dengan k-fold (2 sampai 10) diperoleh hasil RMSE dan SE yang berbeda. Hasil RMSE terkecil terdapat pada k-fold=2 dengan rata-rata keseluruhan RMSE dan SE adalah 0,1526 dan 0,0267.

Tabel 7. Hasil pengujian model arsitektur 3-5-1; *linear sampling*

K-fold	Sampling Type	Model Arsitektur	RMSE	Squared Error
k=2	Linear Sampling	3-5-1	0,195	0,039
k=3	Linear Sampling	3-5-1	0,191	0,037
k=4	Linear Sampling	3-5-1	0,196	0,04
k=5	Linear Sampling	3-5-1	0,178	0,035
k=6	Linear Sampling	3-5-1	0,183	0,035
k=7	Linear Sampling	3-5-1	0,177	0,039
k=8	Linear Sampling	3-5-1	0,171	0,035
k=9	Linear Sampling	3-5-1	0,170	0,035
k=10	Linear Sampling	3-5-1	0,175	0,037
Rata-rata			0,1818	0,0369

Sumber: Data olahan



Sumber: Data olahan

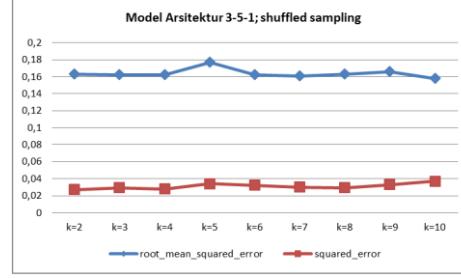
Gambar 5. Grafik pengujian model arsitektur 3-5-1; *linear Sampling*

Pada Tabel 7 dijelaskan model arsitektur 3-5-1; *sampling type= linear sampling* menggunakan *cross validation* dengan k-fold (2 sampai 10) diperoleh hasil RMSE dan SE yang berbeda. Hasil RMSE terkecil terdapat pada k-fold=9 dengan rata-rata keseluruhan RMSE dan SE adalah 0,1818 dan 0,0369.

Tabel 8. Hasil pengujian model arsitektur 3-5-1; *shuffled sampling*

K-fold	Sampling Type	Model Arsitektur	RMSE	Squared Error
k=2	shuffled sampling	3-5-1	0,163	0,027
k=3	shuffled sampling	3-5-1	0,162	0,029
k=4	shuffled sampling	3-5-1	0,162	0,028
k=5	shuffled sampling	3-5-1	0,177	0,034
k=6	shuffled sampling	3-5-1	0,162	0,032
k=7	shuffled sampling	3-5-1	0,161	0,03
k=8	shuffled sampling	3-5-1	0,163	0,029
k=9	shuffled sampling	3-5-1	0,166	0,033
k=10	shuffled sampling	3-5-1	0,158	0,037
Rata-rata			0,1638	0,0310

Sumber: Data olahan



Sumber: Data olahan

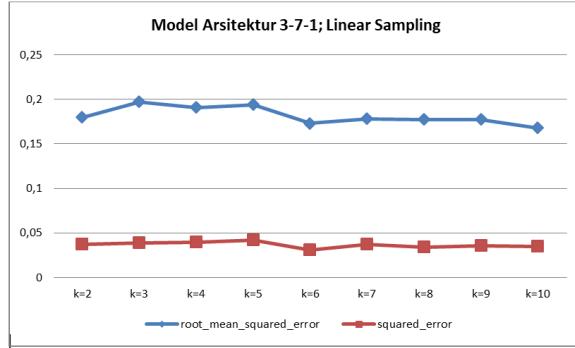
Gambar 6. Grafik pengujian model arsitektur 3-5-1; *shuffled sampling*

Pada Tabel 8 dijelaskan model arsitektur 3-5-1; *sampling type= shuffled sampling* menggunakan *cross validation* dengan k-fold (2 sampai 10) diperoleh hasil RMSE dan SE yang berbeda. Hasil RMSE terkecil terdapat pada k-fold=10 dengan rata-rata keseluruhan RMSE dan SE adalah 0,1638 dan 0,0310.

Tabel 9. Hasil pengujian model arsitektur 3-7-1; *linear sampling*

K-fold	Sampling Type	Model Arsitektur	RMSE	Squared Error
k=2	Linear Sampling	3-7-1	0,18	0,037
k=3	Linear Sampling	3-7-1	0,197	0,039
k=4	Linear Sampling	3-7-1	0,191	0,04
k=5	Linear Sampling	3-7-1	0,194	0,042
k=6	Linear Sampling	3-7-1	0,173	0,031
k=7	Linear Sampling	3-7-1	0,178	0,037
k=8	Linear Sampling	3-7-1	0,177	0,034
k=9	Linear Sampling	3-7-1	0,177	0,036
k=10	Linear Sampling	3-7-1	0,168	0,035
Rata-rata			0,1819	0,0368

Sumber: Data olahan



Sumber: Data olahan

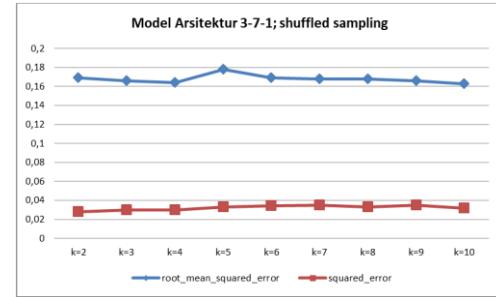
Gambar 7. Grafik pengujian model arsitektur 3-7-1; *linear sampling*

Pada Tabel 9 dijelaskan model arsitektur 3-7-1; *sampling type= linear sampling* menggunakan *cross validation* dengan k-fold (2 sampai 10) diperoleh hasil RMSE dan SE yang berbeda. Hasil RMSE terkecil terdapat pada k-fold=10 dengan rata-rata keseluruhan RMSE dan SE adalah 0,1819 dan 0,0368.

Tabel 10. Hasil pengujian model arsitektur 3-7-1; *shuffled sampling*

K-fold	Sampling Type	Model Arsitektur	RMSE	Squared Error
k=2	shuffled sampling	3-7-1	0,169	0,028
k=3	shuffled sampling	3-7-1	0,166	0,03
k=4	shuffled sampling	3-7-1	0,164	0,03
k=5	shuffled sampling	3-7-1	0,178	0,033
k=6	shuffled sampling	3-7-1	0,169	0,034
k=7	shuffled sampling	3-7-1	0,168	0,035
k=8	shuffled sampling	3-7-1	0,168	0,033
k=9	shuffled sampling	3-7-1	0,166	0,035
k=10	shuffled sampling	3-7-1	0,163	0,032
Rata-rata			0,1678	0,0328

Sumber: Data olahan



Sumber: Data olahan
Gambar 8. Grafik pengujian model arsitektur 3-7-1; *shuffled sampling*

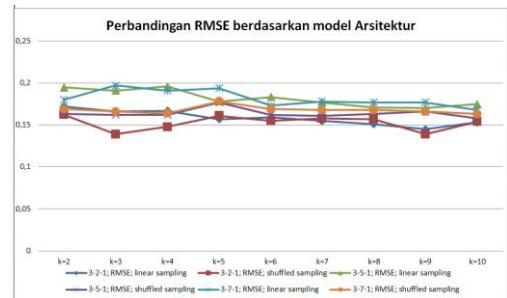
Pada Tabel 10 dijelaskan model arsitektur 3-7-1; *sampling type= shuffled sampling* menggunakan *cross validation* dengan k-fold (2 sampai 10) diperoleh hasil RMSE dan SE yang berbeda. Hasil RMSE terkecil terdapat pada k-fold=10 dengan rata-rata keseluruhan RMSE dan SE adalah 0,1678 dan 0,0328.

Berikut adalah perbandingan seluruh model arsitektur dengan optimasi cross validation menggunakan k-fold seperti yang ditunjukkan pada Tabel 11 dan Gambar 9 berikut.

Tabel 11. Perbandingan seluruh model arsitektur

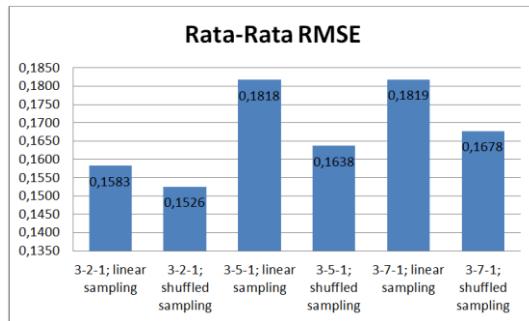
K-fold	3-2-1; RMSE; linear sampling	3-2-1; RMSE; shuffled sampling	3-5-1; RMSE; linear sampling	3-5-1; RMSE; shuffled sampling	3-7-1; RMSE; linear sampling	3-7-1; RMSE; shuffled sampling
k=2	0,172	0,162	0,195	0,163	0,18	0,169
k=3	0,166	0,139	0,191	0,162	0,197	0,166
k=4	0,167	0,148	0,196	0,162	0,191	0,164
k=5	0,157	0,161	0,178	0,177	0,194	0,178
k=6	0,159	0,155	0,183	0,162	0,173	0,169
k=7	0,155	0,158	0,177	0,161	0,178	0,168
k=8	0,151	0,157	0,171	0,163	0,177	0,168
k=9	0,145	0,139	0,17	0,166	0,177	0,166
k=10	0,153	0,154	0,175	0,158	0,168	0,163

Sumber: Data olahan



Sumber: Data olahan
Gambar 9. Perbandingan seluruh model arsitektur

Dari Gambar 9 dijelaskan dari seluruh model yang dioptimasi, model arsitektur 3-2-1 dengan *sampling type: shuffled sampling* memiliki RMSE terkecil pada k-fold=3. Hal ini dibuktikan dengan mengambil rata-rata dari setiap model arsitektur dimana model arsitektur 3-2-1 dengan *sampling type: shuffled sampling* memiliki rata-rata RMSE yang paling baik yakni 0,1526. Berikut hasil lengkap rata-rata RMSE setiap model arsitektur seperti yang ditunjukkan pada Gambar 10 berikut.



Sumber: Data olahan

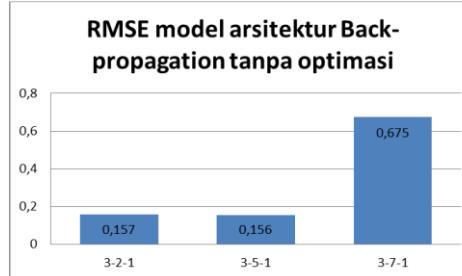
Gambar 10. Rata-rata RMSE seluruh model arsitektur

Berikut adalah hasil pengujian *back-propagation* tanpa menggunakan optimasi dengan parameter yang sama dan model arsitektur yang sama seperti yang ditunjukkan pada Tabel 12 dan Gambar 11 berikut.

Tabel 12. Hasil pengujian *backpropagation* tanpa optimasi

Model Arsitektur	RMSE	Squared Error
3-2-1	0,157	0,025
3-5-1	0,156	0,024
3-7-1	0,675	0,02

Sumber: Data olahan

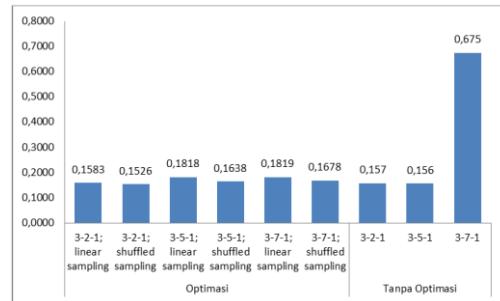


Sumber: Data olahan

Gambar 11. RMSE model arsitektur *Backpro* tanpa optimasi

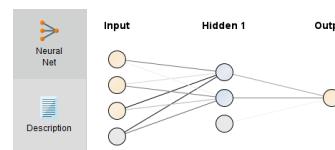
4.2. Analisa hasil pengujian

Dari hasil percobaan yang dilakukan diperoleh hasil optimasi dengan *optimize parameters* dengan *cross validation* pada *back-propagation* terhadap prediksi pertumbuhan produksi Industri mikro dan kecil di Indonesia memperoleh hasil yang lebih baik dibandingkan dengan metode *back-propagation* tanpa optimasi. Hal tersebut dibuktikan dengan menguji tiga model arsitektur (3-2-1; 3-5-1 dan 3-7-1) pada model dengan optimasi dan tanpa optimasi. Hasil menggunakan optimasi mengungguli model *back-propagation* tanpa optimasi dengan melihat RMSE dimana diperoleh RMSE terbaik pada model arsitektur 3-2-1 dengan tipe sampling adalah shuffled sampling. Nilai RMSE yang diperoleh adalah 0,1526 atau selisih **0,0034** dari model arsitektur terbaik backpropagation tanpa optimasi yakni 3-2-1 (0,157) seperti pada Gambar 12 berikut.



Sumber: Data olahan
Gambar 12. Perbandingan model arsitektur *backpro* + optimasi dan tanpa optimasi

Dengan model arsitektur terbaik 3-2-1 dengan *sampling type*: *shuffled sampling* pada k-fold=3 diperoleh hasil lengkap pada Gambar 13 berikut.



Sumber: Data olahan
Gambar 13. Detail model arsitektur terbaik 3-2-1 dengan *sampling type*: *shuffled sampling* pada k-fold=3

Berikut adalah hasil lengkap prediksi optimasi *optimize parameters* dengan *cross validation* dengan *back-propagation* pada pertumbuhan produksi Industri mikro dan kecil di Indonesia seperti yang ditunjukkan pada tabel 13 berikut.

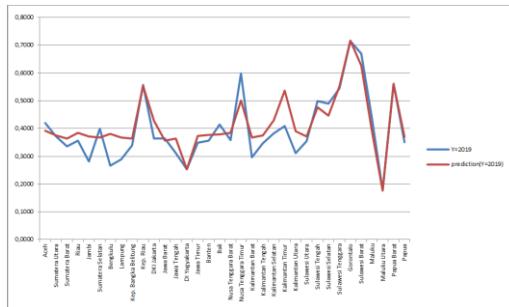
Tabel 13. Hasil prediksi

Y=2019	Prediction (Y=2019)	Error	Prediksi
0,4205	0,3927	0,0277	Benar
0,3714	0,3742	-0,0027	Benar
0,3366	0,3645	-0,0279	Benar
0,3562	0,3836	-0,0274	Benar
0,2808	0,3722	-0,0913	Benar
0,3997	0,3667	0,0329	Benar
0,2655	0,3804	-0,1149	Salah
0,2879	0,3670	-0,0791	Benar
0,3392	0,3631	-0,0239	Benar
0,5569	0,5539	0,0030	Benar
0,3647	0,4278	-0,0631	Benar
0,3633	0,3572	0,0061	Benar
0,3116	0,3633	-0,0516	Benar
0,2537	0,2531	0,0005	Benar
0,3486	0,3731	-0,0245	Benar

$Y=2019$	<i>Prediction</i> ($Y=2019$)	Error	Prediksi
0,3568	0,3775	-0,0207	Benar
0,4154	0,3796	0,0358	Benar
0,3582	0,3843	-0,0261	Benar
0,5988	0,5005	0,0983	Benar
0,2962	0,3673	-0,0711	Benar
0,3466	0,3748	-0,0282	Benar
0,3821	0,4287	-0,0467	Benar
0,4097	0,5360	-0,1263	Salah
0,3112	0,3904	-0,0792	Benar
0,3548	0,3721	-0,0173	Benar
0,4986	0,4772	0,0214	Benar
0,4887	0,4455	0,0432	Benar
0,5432	0,5508	-0,0076	Benar
0,7141	0,7161	-0,0020	Benar
0,6688	0,6258	0,0430	Benar
0,4431	0,3953	0,0478	Benar
0,1780	0,1770	0,0010	Benar
0,5606	0,5600	0,0005	Benar
0,3505	0,3697	-0,0192	Benar

Sumber: Data olahan

Pada Tabel 13 bahwa *error* memiliki klasifikasi lebih kecil 0,09 dan lebih besar 0,001 baik + dan - maka bernilai *true*. Maka sebaliknya adalah *false*. Dari hasil diperoleh prediksi mencapai 94% menggunakan optimasi. Berikut grafik perbandingan hasil prediksi dengan target seperti yang ditunjukkan pada Gambar 14 berikut.



Sumber: Data olahan

Gambar 14. Hasil prediksi model arsitektur terbaik 3-2-1 dengan *sampling type*: *shuffled sampling* pada k-fold=3

Pada gambar 14 hasil prediksi (*line* merah) dengan data sebenarnya (*line* biru) memiliki *error* yang paling kecil dibandingkan dengan semua model yang diuji dengan menggunakan sampling tipe dan k-fold. Hal ini menunjukkan bahwa optimalisasi pada metode *back-propagation* dapat meningkatkan akurasi prediksi dibandingkan dengan menggunakan *back-propagation* standar (Gambar 12).

5. Kesimpulan

Berdasarkan hasil pengujian dan analisis pada *optimize parameters* dengan *cross validation* dengan *back-propagation* terhadap prediksi pertumbuhan produksi Industri mikro dan kecil di Indonesia bahwa model arsitektur terbaik 3-2-1 dengan tipe samping adalah *shuffled sampling*. Nilai RMSE yang diperoleh adalah 0,1526 atau selisih 0,0034 dari model arsitektur terbaik *back-propagation* tanpa optimasi yakni 3-2-1 (0,157). Hasil prediksi mencapai

94 persen pada pertumbuhan produksi Industri mikro dan kecil tahun 2019.

Saran untuk pengembangan lebih lanjut adalah menggunakan nilai parameter yang lebih bervariasi pada pelatihan dan pengujian parameter agar dapat menghasilkan akurasi prediksi yang lebih baik.

Daftar Pustaka

- Budiharjo, Soemartono, T., Windarto, A.P., & Herawan, T., 2018a. Predicting school participation in Indonesia using Back-Propagation Algorithm Model. *International Journal of Control and Automation*, 11(11), 57–68.

Budiharjo, Soemartono, T., Windarto, A.P., & Herawan, T., 2018b. Predicting tuition fee payment problem using backpropagation neural network model. *International Journal of Advanced Science and Technology*, 120, 85–96. <https://doi.org/10.14257/ijast.2018.120.07>

Feibriadi, B., Zamzami, Z., Yunefri, Y.& Wanto, A., 2018. Bipolar function in backpropagation algorithm in predicting Indonesia's coal exports by major destination countries. *IOP Conference Series: Materials Science and Engineering*, 420(1). <https://doi.org/10.1088/1757-899X/420/1/012087>

Indrayati Sijabat, P., Yuhandri, Y., Widi Nurcahyo, G., & Sindar, A., 2020. Algoritma Backpropagation prediksi harga komoditi terhadap karakteristik konsumen produk kopi lokal nasional. *Digital Zone: Jurnal Teknologi Informasi Dan Komunikasi*, 11(1), 96–107. <https://doi.org/10.31849/digitalzone.v11i1.3880>

Kurniawan, E., Wibawanto, H., & Widodo, D.A., 2019. Implementasi metode backpropagation dengan inisialisasi bobot Nguyen Widrow untuk peramalan harga saham. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 6(1), 49. <https://doi.org/10.25126/jtiik.201961904>

Lesnussa, Y.A., Mustamu, C. G., Kondo Lembang, F., & Talakua, M.W., 2018. Application of backpropagation neural networks in predicting rainfall data in Ambon City. *International Journal of Artificial Intelligence Research*, 2(2). <https://doi.org/10.29099/ijair.v2i2.59>

Ma'ruf, A., & Wihestuti, L., 2008. Pertumbuhan Ekonomi Indonesia: Determinan dan Prospeknya. *Jurnal Ekonomi & Studi Pembangunan*, 9(1), 44–55. <https://doi.org/10.18196/jesp.9.1.1526>

Nikentari, N., Kurniawan, H., Ritha, N., Kurniawan, D., Maritim, U., & Ali, R., 2018. Particle swarm optimization untuk prediksi pasang surut air optimization of backpropagation artificial neural network with particle swarm optimization to predict tide level. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 5(5), 605–612. <https://doi.org/10.25126/jtiik2018551055>

Pambudi, E.W., & Miyasto., 2013. Analisis

- Pertumbuhan ekonomi dan faktor-faktor yang mempengaruhi (Kabupaten/Kota di Provinsi Jawa Tengah). *Diponegoro Journal Of Economics*, 2(2), 1–11.
- Prasatya, A., Siregar, R.R.A., & Arianto, R., 2020. Penerapan Metode K-Means dan C4.5 Untuk prediksi penderita diabetes. *Petir*, 13(1), 86–100. <https://doi.org/10.33322/petir.v13i1.925>
- Wanto, A., 2018. Optimasi Prediksi dengan Algoritma Backpropagation dan Conjugate Gradient Beale-Powell Restarts. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 3(3), 370–380. <https://doi.org/10.25077/teknosi.v3i3.2017.370-380>
- Windarto, A.P., Lubis, M.R., & Solikhun, S., 2018. Implementasi JST pada prediksi total laba rugi komprehensif bank umum dan konvensional dengan backpropagation. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 5(4), 411. <https://doi.org/10.25126/jtiik.201854767>
- Windarto, A.P., Na, J., & Wanto, A., 2020. Bagian 2 : Model Arsitektur Neural Network dengan Kombinasi K- Medoids dan Backpropagation pada kasus Pandemi COVID-19 di Indonesia. 4, 1175–1180. <https://doi.org/10.30865/mib.v4i4.2505>