

Prediksi Angka Partisipasi Sekolah dengan Fungsi Pelatihan Gradient Descent With Momentum & Adaptive LR

Anjar Wanto

Program Studi Teknik Informatika STIKOM Tunas Bangsa
Jln. Sudirman Blok A No. 1 - 3 Pematangsiantar, Indonesia
e-mail: anjarwanto@amiktunasbangsa.ac.id

ABSTRAK

Angka Partisipasi Sekolah (APS) dikenal sebagai salah satu indikator keberhasilan pengembangan layanan pendidikan di daerah, baik Provinsi, Kabupaten atau Kota di Indonesia. Semakin tinggi nilai Angka Partisipasi Sekolah, maka daerah tersebut dianggap berhasil dalam memberikan akses ke layanan pendidikan. Tujuan dari penelitian ini adalah untuk memprediksi Angka Partisipasi Sekolah berdasarkan Provinsi di Indonesia mulai dari Aceh hingga Papua. Algoritma prediksi yang digunakan adalah algoritma backpropagation dengan menggunakan fungsi pelatihan gradient descent with momentum & adaptive LR (traingdx). Traingdx adalah fungsi pelatihan jaringan yang memperbarui nilai bobot dan bias berdasarkan momentum gradient descent dan tingkat pembelajaran adaptif. Biasanya algoritma backpropagation menggunakan fungsi gradient descent backpropagation (traingd), akan tetapi pada penelitian ini fungsi pelatihan yang digunakan adalah menggunakan gradient descent with momentum & adaptive LR (traingdx). Data yang digunakan dalam penelitian ini data Angka Partisipasi Sekolah tiap provinsi di Indonesia tahun 2011-2017 usia 19-24 tahun yang diambil dari Badan Pusat Statistik (BPS) Indonesia. Alasan pemilihan Kisaran usia ini adalah karena di usia ini merupakan salah satu faktor yang menentukan keberhasilan pendidikan di suatu negara, khususnya Indonesia. Penelitian ini menggunakan 3 model arsitektur jaringan, yaitu: 5-5-1, 5-15-1 dan 5-25-1. Dari 3 model, model terbaik adalah 5-5-1 dengan iterasi sebesar 130, akurasi 91% dan MSE 0,0023428551. Model ini kemudian digunakan untuk memprediksi Angka Partisipasi Sekolah pada tiap provinsi di Indonesia selama 3 tahun ke depan (2018-2020). Hasil ini diharapkan akan membantu pemerintah Indonesia untuk lebih meningkatkan beasiswa dan meningkatkan kualitas pendidikan di masa depan.

Kata Kunci: Prediksi, APS, Backpropagation, Traingdx

ABSTRACT

School Participation Rate (APS) is known as one of the indicators of the success of the development of educational services in regions both Province, Regency or City in Indonesia. The higher the value of the School Participation Rate, then the area is considered successful in providing access to education services. The purpose of this study is to predict School Participation Rates based on Provinces in Indonesia from Aceh to Papua. The prediction algorithm used is the backpropagation algorithm using the gradient descent with momentum & adaptive LR (traingdx) training function. Traingdx is a network training function that updates weight values and biases based on gradient descent momentum and adaptive learning levels. Usually, the backpropagation algorithm uses the gradient descent backpropagation (traingd) function, but in this study, the training function used is using gradient descent with momentum & adaptive LR (traingdx). The data used in this study data on School Participation Figures for each province in Indonesia in 2011-2017 aged 19-24 years were taken from the Indonesian Central Bureau of Statistics (BPS). The reason for choosing this age range is because at this age is one of the factors that determine the success of education in a country, especially Indonesia. This study uses 3 network architecture models, namely: 5-5-1, 5-15-1 and 5-25-1. Of the 3 models, the best model is 5-5-1 with an iteration of 130, the accuracy of 94% and MSE 0,0008708473. This model is then used to predict School Participation Rates in each province in Indonesia over the next 3 years (2018-2020). These results are expected to help the Indonesian government to further increase scholarships and improve the quality of education in the future..

Keywords: Prediction, APS, Backpropagation, Traingdx.

I. PENDAHULUAN

Angka Partisipasi Sekolah (APS) merupakan proporsi anak sekolah pada usia jenjang pendidikan tertentu dalam kelompok usia yang sesuai dengan jejang pendidikan tersebut. Angka partisipasi sekolah (APS) juga merupakan tolak ukur keberhasilan pendidikan suatu daerah. Hal ini menunjukkan tingkat kemakmuran daerah tersebut. Oleh karena itu, meningkatnya jumlah APS akan berkaitan dengan penurunan tingkat kemiskinan [1]. Semakin tinggi nilai APS, maka daerah tersebut dianggap berhasil dalam memberikan akses ke layanan pendidikan. APS yang tinggi menunjukkan peluang yang lebih besar untuk akses ke pendidikan secara umum. Pada kelompok umur tempat peluang ini terjadi dapat dilihat

dari besarnya APS pada masing-masing kelompok umur [2]. Oleh karena itu, memprediksi nilai APS untuk tahun-tahun berikutnya sangat penting dilakukan, sebagai barometer pemerintah dalam menentukan kebijakan terkait di bidang pendidikan.

Banyak cabang ilmu komputer yang dapat menyelesaikan permasalahan yang bersifat kompleks. Hal ini terbukti dari penelitian terdahulu oleh para peneliti dalam menyelesaikan permasalahan dalam bidang Sistem Pendukung Keputusan [3]–[14], data mining [15]–[19], maupun dalam bidang jaringan saraf tiruan [20]–[31], yang kesemuanya merupakan rumpun dari kecerdasan buatan. Maka dengan melihat permasalahan yang diuraikan tersebut, peneliti bermaksud untuk membuat sebuah penerapan artificial intelligence, yakni memprediksi tingkat APS menggunakan Neural Network Backpropagation dengan fungsi Gradient Descent. Gradient Descent biasanya digunakan untuk menemukan nilai minimum lokal yang dapat dihasilkan dari fungsi parametrik, tujuannya adalah untuk menemukan variabel pada fungsi kesalahan sehingga suatu fungsi dapat memodelkan data dengan kesalahan minimum. Keturunan gradien memiliki kompleksitas linier sehubungan dengan ekspansi data dan juga mudah untuk dihitung secara paralel (menggunakan GPU). Karakteristik ini memungkinkan model jaringan saraf yang cukup besar untuk dilatih dengan jutaan data pelatihan. Namun, penggunaan fungsi gradient descent standar dalam memproses data yang akan diprediksi terkadang membutuhkan waktu yang lama. Sehingga dibutuhkan fungsi lain yang lebih cepat untuk mengolah data, tanpa mengurangi kualitas hasil yang akan ditentukan. Fungsinya adalah Gradient Descent With Momentum & Adaptive Learning Rate (GDMALR). Fungsi ini mampu mempercepat prediksi tanpa terlalu memengaruhi kualitas hasil saat menggunakan standar gradient descent.

Kontribusi dari penelitian ini adalah:

- Sebagai masukan bagi akademisi untuk menggunakan gradient descent dengan fungsi pelatihan Momentum & Adaptive Learning Rate (GDMALR) untuk masalah prediksi, karena pelatihan dengan metode ini terbukti cepat tanpa terlalu memengaruhi kualitas hasil yang diperoleh.
- Sebagai masukan bagi pemerintah untuk dapat membuat kebijakan yang tepat untuk memajukan pendidikan dengan menekan jumlah orang yang tidak bersekolah atau putus sekolah.

A. Jaringan Saraf Tiruan Backpropagation

Algoritma backpropagation merupakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh perceptron dengan banyak layer untuk mengubah bobot-bobot yang ada pada layer tersebut. Backpropagation adalah algoritma iteratif yang mudah dan sederhana yang biasanya berkinerja baik, bahkan dengan data yang kompleks. Algoritma ini sangat bermanfaat dalam berbagai aplikasi, seperti pengenalan, penyeleksian lokasi, dan evaluasi akhir. Pelatihan pada metode backpropagation meliputi 3 fase, fase forward propagation, backpropagation, dan modifikasi bobot. Ciri khas backpropagation melibatkan tiga lapisan: lapisan input, dimana data diperkenalkan ke jaringan; hidden layer, dimana data diproses; dan lapisan output, di mana hasil dari masukan yang diberikan oleh lapisan input [32]–[36].

B. Gradient Descent


Gradient Descent sering digunakan untuk menghitung regulator masalah terbalik, yang secara langsung diterapkan pada ketetapan perbedaan, yang mengukur perbedaan antara evaluasi operator dan data ke versi reguler yang melakukan penggabungan sesuai ketentuan [37]. Tetapi gradient descent memiliki kelemahan terkait dengan parameter laju pembelajaran: jika dipilih terlalu besar, perkiraan akan menjuntai di sekitar titik optimal, bukan mendekati itu. Di sisi lain, jika terlalu kecil, konvergensi mungkin membutuhkan banyak iterasi dan tidak akan mendekati hasil iterasi yang optimal [38]. Akan tetapi kinerja gradient descent dapat ditingkatkan dengan menggunakan tingkat pembelajaran variabel, tingkat pembelajaran konstan, dan tingkat pembelajaran adaptif selama proses pelatihan. Dalam penelitian ini Gradient Descent With Momentum & Adaptive LR digunakan untuk prediksi tingkat partisipasi sekolah. Hasilnya dibandingkan dengan algoritma gradient descent standar, Gradient Descent With Momentum & Adaptive LR lebih baik [39].

II. METODE PENELITIAN

Metode Penelitian yang digunakan pada penelitian ini adalah Jaringan Saraf Tiruan Backpropagation dengan fungsi pelatihan Gradient Descent With Momentum & Adaptive LR. Metode ini mampu melakukan prediksi berdasarkan data yang telah lampau (times series).

A. Tahapan Penelitian

Berikut ini adalah Tahapan penelitian yang digunakan dalam menyelesaikan masalah penelitian ini.



Gambar 1. Tahapan Penelitian

Berdasarkan Gambar 1 dapat dijelaskan bahwa langkah pertama yang dilakukan adalah melakukan pengumpulan data. Setelah data diperoleh dilakukan identifikasi masalah. Sementara dalam penelitian dibutuhkan referensi dasar mengenai jaringan syaraf tiruan backpropagation yang banyak diambil dari jurnal-jurnal sebelumnya dan buku jaringan syaraf tiruan backpropagation. Setelah itu dilakukan Praproses data berupa normaslisasi dari data yang telah dikumpulkan. Selanjutnya menentukan pola arsitektur jaringan yang akan digunakan untuk melakukan prediksi nantinya. Selanjutnya dilakukan pelatihan dan pengujian hasil pengolahan data dengan *software Matlab R2011b*. Kemudian dipilihlah pola arsitektur jaringan terbaik dari beberapa pola yang digunakan, dari pola terbaik ini akan dilakukan prediksi untuk memperoleh hasil prediksi berdasarkan data awal. Tahapan selanjutnya adalah evaluasi akhir yang dilakukan untuk mengetahui apakah hasil prediksi jaraknya masuk akal dan tidak terlalu jauh dengan data awal.

B. Sumber Data

Data yang digunakan adalah data Angka Partisipasi Sekolah (APS) usia 19-24 Tahun pada tiap provinsi di Indonesia tahun 2011-2017. Data bersumber dari Badan Pusat Statistik (BPS) Indonesia[40]. Dapat dilihat pada tabel 1 berikut.

Tabel 1. Data Angka Partisipasi Sekolah (APS) 19-24 Tahun (Tahun 2011-2017)

Provinsi	Tahun						
	2011	2012	2013	2014	2015	2016	2017
Aceh	27,68	28,55	29,18	32,93	33,07	33,94	34,28
Sumatera Utara	16,94	17,27	21,81	24,82	25,16	26,62	26,80
Sumatera Barat	23,95	27,55	30,66	32,89	33,13	34,71	35,45
Riau	15,34	15,81	22,04	24,48	24,85	26,18	27,28
Jambi	15,64	15,22	20,25	22,11	22,22	23,86	24,12
Sumatera Selatan	12,75	13,91	14,08	16,87	17,00	18,07	19,17
Bengkulu	17,02	19,64	24,12	28,14	28,37	28,93	29,90
Lampung	10,39	11,90	16,19	18,67	18,81	19,72	20,96
Kep. Bangka Belitung	8,63	9,30	9,46	12,22	12,73	13,81	14,99

Provinsi	Tahun						
	2011	2012	2013	2014	2015	2016	2017
Kep. Riau	9,67	10,14	14,85	17,40	17,69	18,58	19,13
DKI Jakarta	17,83	18,02	19,65	22,52	22,71	23,06	24,60
Jawa Barat	11,15	12,25	17,34	19,27	19,40	20,37	21,50
Jawa Tengah	11,51	11,83	17,42	20,48	20,57	21,59	22,13
DI Yogyakarta	44,17	44,69	45,86	49,08	49,17	49,95	51,33
Jawa Timur	12,69	14,59	19,49	21,84	21,95	22,67	23,34
Banten	13,56	15,97	18,08	19,61	19,68	20,74	21,33
Bali	18,93	18,99	19,84	23,59	23,75	25,36	26,56
Nusa Tenggara Barat	16,99	17,82	22,64	26,73	26,84	27,79	28,52
Nusa Tenggara Timur	17,40	17,92	22,88	26,22	26,54	26,75	27,80
Kalimantan Barat	11,94	14,17	19,27	23,18	23,32	24,75	25,80
Kalimantan Tengah	13,05	14,04	19,89	22,31	22,47	22,72	24,15
Kalimantan Selatan	13,62	16,48	16,95	20,36	20,53	21,89	23,53
Kalimantan Timur	16,92	20,33	25,04	27,34	27,55	28,88	30,04
Kalimantan Utara	0,00	0,00	0,00	0,00	17,87	19,07	20,72
Sulawesi Utara	15,16	16,12	16,36	20,91	21,31	22,82	24,22
Sulawesi Tengah	16,72	16,74	21,76	25,05	25,13	25,57	26,31
Sulawesi Selatan	21,46	23,17	27,80	30,23	30,64	31,48	32,16
Sulawesi Tenggara	21,48	23,62	24,00	28,78	28,89	29,31	30,03
Gorontalo	19,85	20,46	23,27	27,94	28,38	28,98	29,21
Sulawesi Barat	13,03	14,65	18,04	21,53	21,97	22,36	23,49
Maluku	26,71	28,98	33,80	36,44	36,60	37,51	38,20
Maluku Utara	19,33	21,79	26,42	30,85	31,25	31,75	32,10
Papua Barat	16,46	20,03	24,10	29,66	29,96	31,45	31,92
Papua	12,81	13,86	17,50	22,48	22,55	23,75	24,57

Sumber : Badan Pusat Statistik (BPS) Indonesia

C. Normalisasi

Sebelum diproses, data awal yang diperoleh dari Badan Pusat Statistik dibagi menjadi 2 bagian, yakni data pelatihan dan data pengujian. Data pelatihan dan data pengujian inilah yang nantinya akan dinormalisasi. Data pelatihan diambil dari data tahun 2011-2015 dengan target tahun 2016. Sedangkan data pengujian diambil dari data tahun 2012-2016 dengan target tahun 2017. Kedua data ini nantinya dinormalisasi menggunakan fungsi Sigmoid (tidak pernah mencapai 0 ataupun 1). Rumus normalisasi dapat dilihat pada persamaan berikut.

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

Keterangan :

(x' = Normalisasi data, x = Data yang akan dinormalisasi, a = Data terendah, b = Data tertinggi)

Tabel 2. Normalisasi Data Pelatihan (Tahun 2011-2015 / Target Tahun 2016)

Provinsi	2011	2012	2013	2014	2015	Target (2016)
Aceh	0,54332	0,55726	0,56735	0,62741	0,62965	0,64358
Sumatera Utara	0,37131	0,37660	0,44931	0,49752	0,50296	0,52635
Sumatera Barat	0,48358	0,54124	0,59105	0,62677	0,63061	0,65592
Riau	0,34569	0,35321	0,45299	0,49207	0,49800	0,51930

Provinsi	2011	2012	2013	2014	2015	Target (2016)
Jambi	0,35049	0,34376	0,42432	0,45411	0,45588	0,48214
Sumatera Selatan	0,30420	0,32278	0,32551	0,37019	0,37227	0,38941
Bengkulu	0,37259	0,41455	0,48631	0,55069	0,55437	0,56334
Lampung	0,26641	0,29059	0,35930	0,39902	0,40126	0,41584
Kep. Bangka Belitung	0,23822	0,24895	0,25151	0,29572	0,30388	0,32118
Kep. Riau	0,25487	0,26240	0,33784	0,37868	0,38332	0,39758
DKI Jakarta	0,38557	0,38861	0,41471	0,46068	0,46372	0,46933
Jawa Barat	0,27858	0,29620	0,37772	0,40863	0,41071	0,42625
Jawa Tengah	0,28434	0,28947	0,37900	0,42801	0,42945	0,44579
DI Yogyakarta	0,80743	0,81576	0,83449	0,88607	0,88751	0,90000
Jawa Timur	0,30324	0,33367	0,41215	0,44979	0,45155	0,46308
Banten	0,31718	0,35578	0,38957	0,41407	0,41520	0,43217
Bali	0,40318	0,40414	0,41776	0,47782	0,48038	0,50617
Nusa Tenggara Barat	0,37211	0,38541	0,46260	0,52811	0,52987	0,54509
Nusa Tenggara Timur	0,37868	0,38701	0,46645	0,51994	0,52507	0,52843
Kalimantan Barat	0,29123	0,32695	0,40863	0,47125	0,47349	0,49640
Kalimantan Tengah	0,30901	0,32486	0,41856	0,45732	0,45988	0,46388
Kalimantan Selatan	0,31814	0,36394	0,37147	0,42609	0,42881	0,45059
Kalimantan Timur	0,37099	0,42561	0,50104	0,53788	0,54124	0,56254
Kalimantan Utara	0,10000	0,10000	0,10000	0,10000	0,38621	0,40543
Sulawesi Utara	0,34280	0,35818	0,36202	0,43489	0,44130	0,46549
Sulawesi Tengah	0,36779	0,36811	0,44851	0,50120	0,50248	0,50953
Sulawesi Selatan	0,44370	0,47109	0,54525	0,58416	0,59073	0,60418
Sulawesi Tenggara	0,44402	0,47830	0,48438	0,56094	0,56270	0,56943
Gorontalo	0,41792	0,42769	0,47269	0,54749	0,55453	0,56414
Sulawesi Barat	0,30869	0,33463	0,38893	0,44482	0,45187	0,45812
Maluku	0,52779	0,56414	0,64134	0,68362	0,68619	0,70076
Maluku Utara	0,40959	0,44899	0,52314	0,59409	0,60050	0,60851
Papua Barat	0,36362	0,42080	0,48599	0,57504	0,57984	0,60370
Papua	0,30517	0,32198	0,38028	0,46004	0,46116	0,48038

Tabel 3.Normalisasi Data Pengujian (Tahun 2012-2016 / Target Tahun 2017)

Provinsi	2012	2013	2014	2015	2016	Target (2017)
Aceh	0,54496	0,55478	0,61323	0,61541	0,62897	0,63427
Sumatera Utara	0,36916	0,43992	0,48683	0,49213	0,51488	0,51769
Sumatera Barat	0,52938	0,57785	0,61260	0,61635	0,64097	0,65250
Riau	0,34641	0,44350	0,48153	0,48730	0,50803	0,52517
Jambi	0,33721	0,41560	0,44459	0,44631	0,47187	0,47592
Sumatera Selatan	0,31679	0,31944	0,36293	0,36495	0,38163	0,39877
Bengkulu	0,40610	0,47592	0,53857	0,54216	0,55089	0,56600
Lampung	0,28547	0,35233	0,39098	0,39316	0,40734	0,42667
Kep. Bangka Belitung	0,24494	0,24744	0,29045	0,29840	0,31523	0,33363
Kep. Riau	0,25804	0,33144	0,37119	0,37571	0,38958	0,39815
DKI Jakarta	0,38085	0,40625	0,45098	0,45395	0,45940	0,48340
Jawa Barat	0,29092	0,37025	0,40033	0,40236	0,41748	0,43509

Provinsi	2012	2013	2014	2015	2016	Target (2017)
Jawa Tengah	0,28438	0,37150	0,41919	0,42059	0,43649	0,44491
DI Yogyakarta	0,79651	0,81475	0,86493	0,86634	0,87849	0,90000
Jawa Timur	0,32739	0,40376	0,44039	0,44210	0,45332	0,46376
Banten	0,34890	0,38178	0,40563	0,40672	0,42324	0,43244
Bali	0,39597	0,40921	0,46766	0,47015	0,49525	0,51395
Nusa Tenggara Barat	0,37773	0,45285	0,51660	0,51831	0,53312	0,54450
Nusa Tenggara Timur	0,37929	0,45659	0,50865	0,51364	0,51691	0,53327
Kalimantan Barat	0,32085	0,40033	0,46127	0,46345	0,48574	0,50210
Kalimantan Tengah	0,31882	0,40999	0,44771	0,45020	0,45410	0,47639
Kalimantan Selatan	0,35685	0,36417	0,41732	0,41997	0,44117	0,46673
Kalimantan Timur	0,41685	0,49026	0,52611	0,52938	0,55011	0,56819
Kalimantan Utara	0,10000	0,10000	0,10000	0,37851	0,39721	0,42293
Sulawesi Utara	0,35124	0,35498	0,42589	0,43213	0,45566	0,47748
Sulawesi Tengah	0,36090	0,43914	0,49041	0,49166	0,49852	0,51005
Sulawesi Selatan	0,46111	0,53327	0,57115	0,57754	0,59063	0,60123
Sulawesi Tenggara	0,46813	0,47405	0,54855	0,55026	0,55681	0,56803
Gorontalo	0,41888	0,46267	0,53546	0,54231	0,55167	0,55525
Sulawesi Barat	0,32833	0,38116	0,43555	0,44241	0,44849	0,46610
Maluku	0,55167	0,62679	0,66793	0,67043	0,68461	0,69536
Maluku Utara	0,43961	0,51177	0,58081	0,58704	0,59484	0,60029
Papua Barat	0,41218	0,47561	0,56226	0,56694	0,59016	0,59749
Papua	0,31601	0,37274	0,45036	0,45145	0,47015	0,48293

III. HASIL DAN PEMBAHASAN

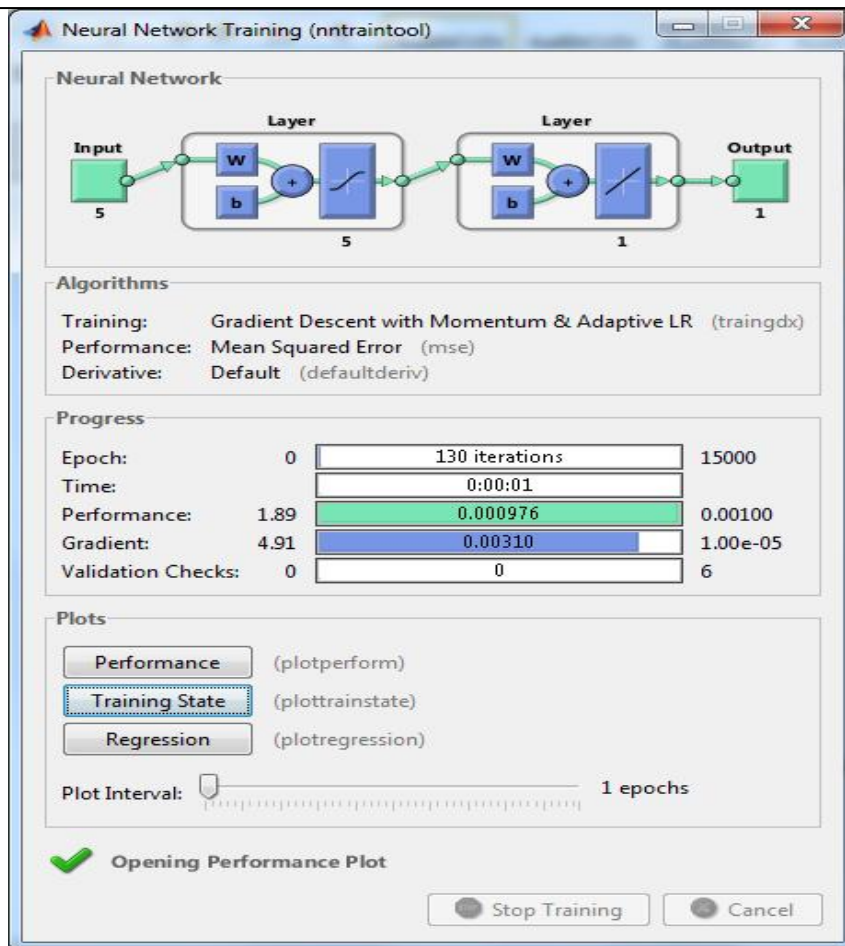
Penelitian ini menggunakan 3 model arsitektur, antara lain: 5-5-1(5 merupakan data input layer, 5 merupakan data hidden layer dan 1 merupakan data output layer), 5-15-1(5 merupakan data input layer, 15 merupakan data hidden layer dan 1 merupakan data output layer), 5-25-1(5 merupakan data input layer, 25 merupakan data hidden layer dan 1 merupakan data output layer). Parameter pelatihan dan pengujian menggunakan Target Minimum Error = 0,001 - 0,05, Maksimum Epoch = 15000 dan Tingkat Pembelajaran = 0,01 serta fungsi pelatihan Gradient Descent With Momentum & Adaptive LR(*traingdx*) dalam pemrosesan sistem menggunakan aplikasi Matlab.

Tabel 4.Parameter dan kode program yang digunakan secara umum

```

net=newff(minmax(P),[Hiden,Target],{
'tansig','purelin'},'traingdx');
net.LW{1,1};
net.b{1};
net.LW{2,1};
net.b{2};
net.trainParam.epochs=15000;
net.trainParam.goal = 0.001;
net.trainParam.Lr = 0.01;
net.trainParam.show = 1000;
net=train(net,P,T)
    
```

Dari ke 3 model arsitektur tersebut, arsitektur yang terbaik ialah 5-5-1 dengan tingkat akurasi sebesar 91% serta epoch sebesar 130 iterasi. Untuk lebih jelasnya dapat dilihat pada gambar berikut:



Gambar 2. Data pelatihan dengan model arsitektur 5-5-1

Berdasarkan gambar 1 dapat dijelaskan bahwa pelatihan dengan menggunakan model arsitektur 5-5-1 menghasilkan Epoch sebesar 130 iterasi dengan waktu yang sangat singkat, yakni hanya 1 detik.

Pada tabel 5 terdapat pola 1 s/d 34, ini merupakan data provinsi. Nilai Target diperoleh dari tabel data latih dan data uji yang sudah dinormalisasi. Nilai Output diperoleh dari rumus $[a, P_f, A_f, e, Perf] = sim(net, P, [], [], T)$ yang dimasukkan pada aplikasi Matlab dari input dan data target data latih serta data uji. Nilai Error diperoleh dari : $Target - Output$. SSE diperoleh dari : $Error^2$ (^: Pangkat). Jumlah SSE adalah jumlah dari keseluruhan SSE. MSE diperoleh dari : $jumlah\ SSE / 34$ (jumlah data). Hasil bernilai Benar (1) apabila nilai $error \leq 0,09$, sedangkan Salah (0) apabila sebaliknya. Sedangkan akurasi sebesar 91% diperoleh dari Hasil yang benar (1) dibagi 34 (jumlah data provinsi) dikalikan 100.

Tabel 5. Model arsitektur terbaik dengan model 5-5-1

Data Pelatihan					Data Pengujian				
Pola	Target	Output	Error	SSE	Target	Output	Error	SSE	Hasil
Pola 1	0,64358	0,67530	-0,03172	0,0010059311	0,63427	0,72650	-0,09223	0,0085066572	1
Pola 2	0,52635	0,52230	0,00405	0,0000163729	0,51769	0,55030	-0,03261	0,0010634473	1
Pola 3	0,65592	0,68690	-0,03098	0,0009600135	0,65250	0,70750	-0,05500	0,0030246250	1
Pola 4	0,51930	0,51800	0,00130	0,0000016882	0,52517	0,53620	-0,01103	0,0001216506	1
Pola 5	0,48214	0,48660	-0,00446	0,0000198725	0,47592	0,48480	-0,00888	0,0000788453	1
Pola 6	0,38941	0,41270	-0,02329	0,0005424516	0,39877	0,44280	-0,04403	0,0019384078	1
Pola 7	0,56334	0,57350	-0,01016	0,0001031577	0,56600	0,62580	-0,05980	0,0035755274	1
Pola 8	0,41584	0,41330	0,00254	0,0000064305	0,42667	0,42340	0,00327	0,0000106966	1
Pola 9	0,32118	0,41970	-0,09852	0,0097059577	0,33363	0,43940	-0,10577	0,0111882321	1
Pola 10	0,39758	0,41350	-0,01592	0,0002535235	0,39815	0,40740	-0,00925	0,0000855767	1

Data Pelatihan					Data Pengujian					
Pola	Target	Output	Error	SSE	Target	Output	Error	SSE	Hasil	
Pola 11	0,46933	0,48750	-0,01817	0,0003301733	0,48340	0,51790	-0,03450	0,0011901452	1	
Pola 12	0,42625	0,42730	-0,00105	0,0000011104	0,43509	0,42730	0,00779	0,0000606326	1	
Pola 13	0,44579	0,42880	0,01699	0,0002885169	0,44491	0,44030	0,00461	0,0000212108	1	
Pola 14	0,90000	0,81340	0,08660	0,0074995600	0,90000	0,84130	0,05870	0,0034456900	0	
Pola 15	0,46308	0,45400	0,00908	0,0000825024	0,46376	0,47840	-0,01464	0,0002142160	1	
Pola 16	0,43217	0,43790	-0,00573	0,0000328080	0,43244	0,46060	-0,02816	0,0007931449	1	
Pola 17	0,50617	0,49660	0,00957	0,0000915115	0,51395	0,53900	-0,02505	0,0006275547	1	
Pola 18	0,54509	0,54480	0,00029	0,0000000813	0,54450	0,59180	-0,04730	0,0022376310	1	
Pola 19	0,52843	0,54780	-0,01937	0,0003752578	0,53327	0,58350	-0,05023	0,0025225619	1	
Pola 20	0,49640	0,45220	0,04420	0,0019533215	0,50210	0,50220	-0,00010	0,0000000092	1	
Pola 21	0,46388	0,46480	-0,00092	0,0000008393	0,47639	0,48360	-0,00721	0,0000520118	1	
Pola 22	0,45059	0,42030	0,03029	0,0009175199	0,46673	0,47620	-0,00947	0,0000897735	1	
Pola 23	0,56254	0,58330	-0,02076	0,0004308720	0,56819	0,60720	-0,03901	0,0015220730	1	
Pola 24	0,40543	0,36720	0,03823	0,0014611831	0,42293	0,33830	0,08463	0,0071622471	0	
Pola 25	0,46549	0,42560	0,03989	0,0015908520	0,47748	0,48140	-0,00392	0,0000153738	1	
Pola 26	0,50953	0,52270	-0,01317	0,0001734613	0,51005	0,55340	-0,04335	0,0018789970	1	
Pola 27	0,60418	0,64740	-0,04322	0,0018676067	0,60123	0,66420	-0,06297	0,0039655543	1	
Pola 28	0,56943	0,57750	-0,00807	0,0000651341	0,56803	0,65800	-0,08997	0,0080945304	1	
Pola 29	0,56414	0,56530	-0,00116	0,0000013360	0,55525	0,62840	-0,07315	0,0053508726	1	
Pola 30	0,45812	0,43500	0,02312	0,0005344474	0,46610	0,47820	-0,01210	0,0001463690	1	
Pola 31	0,70076	0,72590	-0,02514	0,0006319813	0,69536	0,74230	-0,04694	0,0022030505	1	
Pola 32	0,60851	0,62190	-0,01339	0,0001793320	0,60029	0,67480	-0,07451	0,0055514083	1	
Pola 33	0,60370	0,57920	0,02450	0,0006004315	0,59749	0,65120	-0,05371	0,0028851025	1	
Pola 34	0,48038	0,43130	0,04908	0,0024088837	0,48293	0,48870	-0,00577	0,0000332473	1	
Jlh. SSE				0,0341341226	Jlh. SSE				0,0796570733	91%
MSE				0,0010039448	MSE				0,0023428551	

Pada tabel 6 dapat dilihat perbandingan Iterasi, MSE dan akurasi dari pelatihan dan pengujian data menggunakan 3 model arsitektur 5-5-1, 5-15-1 dan 5-25-1.

Tabel 6. Model arsitektur terbaik dengan model 5-5-1

No	Arsitektur	Gradient Descent With Momentum & Adaptive LR (traingdx)		
		Iterasi	MSE	Akurasi
1	5-5-1	130	0,0008708473	91%
2	5-15-1	322	0,0008283832	66%
3	5-25-1	96	0,0006339944	89%

Pada tabel 7 dapat dilihat perbandingan data awal dengan data hasil prediksi Angka Partisipasi Sekolah (APS) menggunakan jaringan saraf tiruan Backpropagation dengan fungsi pelatihan Gradient Descent With Momentum & Adaptive LR tahun 2018 sampai dengan tahun 2020.

Tabel 7. Perbandingan data Awal APS (Tahun 2011-2017) dengan hasil prediksi (Tahun 2018-2020)

Provinsi	Tahun							Prediksi dengan Traingdx		
	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
Aceh	27,68	28,55	29,18	32,93	33,07	33,94	34,28	40,94	43,50	42,73
Sumatera Utara	16,94	17,27	21,81	24,82	25,16	26,62	26,80	33,72	40,97	42,31

Provinsi	Tahun							Prediksi dengan Traingdx		
	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
Sumatera Barat	23,95	27,55	30,66	32,89	33,13	34,71	35,45	41,02	43,52	42,69
Riau	15,34	15,81	22,04	24,48	24,85	26,18	27,28	33,34	41,14	42,21
Jambi	15,64	15,22	20,25	22,11	22,22	23,86	24,12	31,31	39,78	42,19
Sumatera Selatan	12,75	13,91	14,08	16,87	17,00	18,07	19,17	30,13	39,57	42,52
Bengkulu	17,02	19,64	24,12	28,14	28,37	28,93	29,90	36,88	42,51	42,86
Lampung	10,39	11,90	16,19	18,67	18,81	19,72	20,96	29,45	39,23	42,61
Kep. Bangka Belitung	8,63	9,30	9,46	12,22	12,73	13,81	14,99	30,11	40,68	42,42
Kep. Riau	9,67	10,14	14,85	17,40	17,69	18,58	19,13	29,09	39,47	42,72
DKI Jakarta	17,83	18,02	19,65	22,52	22,71	23,06	24,60	31,93	39,62	42,18
Jawa Barat	11,15	12,25	17,34	19,27	19,40	20,37	21,50	29,54	39,34	42,57
Jawa Tengah	11,51	11,83	17,42	20,48	20,57	21,59	22,13	29,86	38,75	42,52
DI Yogyakarta	44,17	44,69	45,86	49,08	49,17	49,95	51,33	47,04	43,52	42,66
Jawa Timur	12,69	14,59	19,49	21,84	21,95	22,67	23,34	30,91	39,43	42,31
Banten	13,56	15,97	18,08	19,61	19,68	20,74	21,33	30,48	39,44	42,45
Bali	18,93	18,99	19,84	23,59	23,75	25,36	26,56	32,86	39,93	42,12
Nusa Tenggara Barat	16,99	17,82	22,64	26,73	26,84	27,79	28,52	35,44	41,75	42,67
Nusa Tenggara Timur	17,40	17,92	22,88	26,22	26,54	26,75	27,80	34,85	41,74	42,59
Kalimantan Barat	11,94	14,17	19,27	23,18	23,32	24,75	25,80	31,95	39,50	42,09
Kalimantan Tengah	13,05	14,04	19,89	22,31	22,47	22,72	24,15	31,03	39,72	42,25
Kalimantan Selatan	13,62	16,48	16,95	20,36	20,53	21,89	23,53	30,93	38,72	42,23
Kalimantan Timur	16,92	20,33	25,04	27,34	27,55	28,88	30,04	36,04	42,75	42,76
Kalimantan Utara	0,00	0,00	0,00	0,00	17,87	19,07	20,72	28,48	39,40	41,74
Sulawesi Utara	15,16	16,12	16,36	20,91	21,31	22,82	24,22	31,12	38,18	42,14
Sulawesi Tengah	16,72	16,74	21,76	25,05	25,13	25,57	26,31	33,56	40,90	42,37
Sulawesi Selatan	21,46	23,17	27,80	30,23	30,64	31,48	32,16	38,87	43,57	42,88
Sulawesi Tenggara	21,48	23,62	24,00	28,78	28,89	29,31	30,03	37,19	42,52	42,91
Gorontalo	19,85	20,46	23,27	27,94	28,38	28,98	29,21	36,75	42,19	42,85
Sulawesi Barat	13,03	14,65	18,04	21,53	21,97	22,36	23,49	30,86	38,77	42,27
Maluku	26,71	28,98	33,80	36,44	36,60	37,51	38,20	43,56	43,55	42,43
Maluku Utara	19,33	21,79	26,42	30,85	31,25	31,75	32,10	39,72	43,21	42,84
Papua Barat	16,46	20,03	24,10	29,66	29,96	31,45	31,92	38,82	42,44	42,86
Papua	12,81	13,86	17,50	22,48	22,55	23,75	24,57	31,33	38,43	42,19

IV. KESIMPULAN

Berdasarkan uraian sebelumnya, dapat ditarik kesimpulan sebagai berikut:

1. Berdasarkan hasil prediksi untuk tahun 2018-2020, dapat dilihat bahwa Angka Partisipasi Sekolah (APS) pada tiap Provinsi di Indonesia mengalami kenaikan dibandingkan tahun-tahun sebelumnya, akan tetapi selisih antara data awal dengan data hasil prediksi terlihat sedikit lebih jauh.
2. Gradient descent with Momentum & Adaptive LR (GDMALR) cepat digunakan dalam memprediksi suatu data.
3. Penentuan parameter jaringan optimal hanya dapat dilakukan berdasarkan proses pembelajaran dan penentuan kesalahan sehingga lamanya waktu belajar tidak dapat ditentukan dengan pasti.
4. Jumlah iterasi tidak dapat ditentukan oleh ukuran akurasi pengenalan pola yang diinginkan tetapi ditentukan oleh parameter jaringan yang digunakan, kondisi awal jaringan dan karakteristik data input.

5. Kecepatan untuk mendapatkan pola hasil pelatihan tidak ditentukan oleh kecepatan komputasi, tetapi ditentukan oleh parameter jaringan dan solusi ruang yang dicari

V.DAFTAR PUSTAKA

- [1] P. Karini, "Pengaruh Tingkat Kemiskinan Terhadap Angka Partisipasi Sekolah Usia 16-18 Tahun Di Provinsi Kepulauan Bangka Belitung," *Al-Ishlah: Jurnal Pendidikan*, vol. 10, no. 1, pp. 103–115, 2018.
- [2] M. F. Akbar, "Evaluasi Kebijakan Program Pemberian Dana Bantuan Operasional Sekolah," *Jurnal Analisis Kebijakan Dan Pelayanan Publik*, vol. 2, no. 1, pp. 47–64, 2016.
- [3] M. Masitha, D. Hartama, and A. Wanto, "Analisa Metode (AHP) pada Pembelian Sepatu Sekolah Berdasarkan Konsumen," *Seminar Nasional Sains & Teknologi Informasi (SENSASI)*, vol. 1, no. 1, pp. 338–342, 2018.
- [4] L. P. Purba, A. P. Windarto, and A. Wanto, "Faktor Terbesar Rendahnya Minat Ber-KB (Keluarga Berencana) dengan Metode ELECTRE II," *Seminar Nasional Sains & Teknologi Informasi (SENSASI)*, vol. 1, no. 1, pp. 369–374, 2018.
- [5] N. Rofiqo, A. P. Windarto, and A. Wanto, "Penerapan Metode VIKOR Pada Faktor Penyebab Rendahnya Minat Mahasiswa Dalam Menulis Artikel Ilmiah," *Seminar Nasional Sains & Teknologi Informasi (SENSASI)*, vol. 1, no. 1, pp. 228–237, 2018.
- [6] A. Wanto, "Analisis Penerapan Fuzzy Inference System (FIS) Dengan Metode Mamdani Pada Sistem Prediksi Mahasiswa Non Aktif (Studi Kasus : AMIK Tunas Bangsa Pematangsiantar)," in *Seminar Nasional Inovasi Dan Teknologi Informasi (SNITI) 3*, 2016, vol. 3, pp. 393–400.
- [7] S. R. Ningsih, D. Hartama, A. Wanto, I. Parlina, and Solikhun, "Penerapan Sistem Pendukung Keputusan Pada Pemilihan Objek Wisata di Simalungun," in *Seminar Nasional Teknologi Komputer & Sains (SAINTEKS)*, 2019, pp. 731–735.
- [8] R. A. Hutasoit, S. Solikhun, and A. Wanto, "Analisa Pemilihan Barista dengan Menggunakan Metode TOPSIS (Studi Kasus: Mo Coffee)," *KOMIK (Konferensi Nasional Teknologi Informasi dan Komputer)*, vol. 2, no. 1, pp. 256–262, 2018.
- [9] A. Wanto and H. Damanik, "Analisis Penerapan Sistem Pendukung Keputusan Terhadap Seleksi Penerima Beasiswa BBM (Bantuan Belajar Mahasiswa) Pada Perguruan Tinggi Menggunakan Metode Simple Additive Weighting (SAW) (Studi Kasus : AMIK Tunas Bangsa Pematangsiantar)," in *Seminar Nasional Rekayasa (SNTR) II*, 2015, no. 2, pp. 323–333.
- [10] T. Imandasari, A. Wanto, and A. P. Windarto, "Analisis Pengambilan Keputusan Dalam Menentukan Mahasiswa PKL Menggunakan Metode PROMETHEE," *Jurnal Riset Komputer (JURIKOM)*, vol. 5, no. 3, pp. 234–239, 2018.
- [11] M. Widyasuti, A. Wanto, D. Hartama, and E. Purwanto, "Rekomendasi Penjualan Aksesoris Handphone Menggunakan Metode Analytical Hierarchy Process (AHP)," *Konferensi Nasional Teknologi Informasi dan Komputer*, vol. 1, no. 1, pp. 27–32, 2017.
- [12] S. Sundari, A. Wanto, Saifullah, and I. Gunawan, "Sistem Pendukung Keputusan Dengan Menggunakan Metode Electre Dalam Merekomendasikan Dosen Berprestasi Bidang Ilmu Komputer (Study Kasus di AMIK & STIKOM Tunas Bangsa)," in *Seminar Nasional Multi Disiplin Ilmu*, 2017, pp. 1–6.
- [13] A. Wanto and E. Kurniawan, "Seleksi Penerimaan Asisten Laboratorium Menggunakan Algoritma AHP Pada AMIK-STIKOM Tunas Bangsa Pematangsiantar," *Jurnal Informatika dan Komputer (JIKO)*, vol. 3, no. 1, pp. 11–18, 2018.
- [14] S. Sundari, S. M. Sinaga, I. S. Damanik, and A. Wanto, "Sistem Pendukung Keputusan Pemilihan Peserta Olimpiade Matematika SMA Swasta Teladan Pematangsiantar Dengan Metode Electre," in *Seminar Nasional Teknologi Komputer & Sains (SAINTEKS)*, 2019, pp. 793–799.
- [15] I. Parlina, A. P. Windarto, A. Wanto, and M. R. Lubis, "Memanfaatkan Algoritma K-Means dalam Menentukan Pegawai yang Layak Mengikuti Assessment Center untuk Clustering Program SDP," *CESS (Journal of Computer Engineering System and Science)*, vol. 3, no. 1, pp. 87–93, 2018.
- [16] S. Sudirman, A. P. Windarto, and A. Wanto, "Data Mining Tools | RapidMiner : K-Means Method on Clustering of Rice Crops by Province as Efforts to Stabilize Food Crops In Indonesia," *IOP Conference Series: Materials Science and Engineering*, vol. 420, no. 12089, pp. 1–8, 2018.
- [17] H. Siahaan, H. Mawengkang, S. Efendi, A. Wanto, and A. P. Windarto, "Application of Classification Method C4 . 5 on Selection of Exemplary Teachers," in *IOP Conference Series*, 2018,

- pp. 1–6.
- [18] R. W. Sari, A. Wanto, and A. P. Windarto, “Implementasi Rapidminer dengan Metode K-Means (Study Kasus : Imunisasi Campak pada Balita Berdasarkan Provinsi),” *KOMIK (Konferensi Nasional Teknologi Informasi dan Komputer)*, vol. 2, no. 1, pp. 224–230, 2018.
- [19] M. G. Sadewo, A. P. Windarto, and A. Wanto, “Penerapan Algoritma Clustering dalam Mengelompokkan Banyaknya Desa/Kelurahan Menurut Upaya Antisipasi/ Mitigasi Bencana Alam Menurut Provinsi dengan K-Means,” *KOMIK (Konferensi Nasional Teknologi Informasi dan Komputer)*, vol. 2, no. 1, pp. 311–319, 2018.
- [20] 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. 2018.
- [21] N. Nasution, A. Zamsuri, L. Lisnawita, and A. Wanto, “Polak-Ribiere updates analysis with binary and linear function in determining coffee exports in Indonesia,” *IOP Conference Series: Materials Science and Engineering*, vol. 420, no. 12089, pp. 1–9, 2018.
- [22] 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.
- [23] S. P. Siregar and A. Wanto, “Analysis of Artificial Neural Network Accuracy Using Backpropagation Algorithm In Predicting Process (Forecasting),” *International Journal Of Information System & Technology*, vol. 1, no. 1, pp. 34–42, 2017.
- [24] B. K. Sihotang and A. Wanto, “Analisis Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Tamu Pada Hotel Non Bintang,” *Jurnal Teknologi Informasi Techno*, vol. 17, no. 4, pp. 333–346, 2018.
- [25] B. Febriadi, Z. Zamzami, Y. Yunefri, and A. Wanto, “Bipolar function in backpropagation algorithm in predicting Indonesia’s coal exports by major destination countries,” *IOP Conference Series: Materials Science and Engineering*, vol. 420, no. 12089, pp. 1–9, 2018.
- [26] E. Hartato, D. Sitorus, and A. Wanto, “Analisis Jaringan Saraf Tiruan Untuk Prediksi Luas Panen Biofarmaka di Indonesia,” *Jurnal semanTIK*, vol. 4, no. 1, pp. 49–56, 2018.
- [27] J. Wahyuni, Y. W. Paranthi, and A. Wanto, “Analisis Jaringan Saraf Dalam Estimasi Tingkat Pengangguran Terbuka Penduduk Sumatera Utara,” *Jurnal Infomedia*, vol. 3, no. 1, pp. 18–24, 2018.
- [28] 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,” *International Journal Of Information System & Technology*, vol. 1, no. 1, pp. 43–54, 2017.
- [29] M. A. P. Hutabarat, M. Julham, and A. Wanto, “Penerapan Algoritma Backpropagation Dalam Memprediksi Produksi Tanaman Padi Sawah Menurut Kabupaten/Kota di Sumatera Utara,” *Jurnal semanTIK*, vol. 4, no. 1, pp. 77–86, 2018.
- [30] I. A. R. Simbolon, F. Yatussa’ada, and A. Wanto, “Penerapan Algoritma Backpropagation dalam Memprediksi Persentase Penduduk Buta Huruf di Indonesia,” *Jurnal Informatika Upgris*, vol. 4, no. 2, pp. 163–169, 2018.
- [31] A. Wanto, “Penerapan Jaringan Saraf Tiruan Dalam Memprediksi Jumlah Kemiskinan Pada Kabupaten/Kota Di Provinsi Riau,” *Kumpulan jurnal Ilmu Komputer (KLIK)*, vol. 5, no. 1, pp. 61–74, 2018.
- [32] R. E. Pranata, S. P. Sinaga, and A. Wanto, “Estimasi Wisatawan Mancanegara Yang Datang ke Sumatera Utara Menggunakan Jaringan Saraf,” *Jurnal semanTIK*, vol. 4, no. 1, pp. 97–102, 2018.
- [33] 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.
- [34] I. S. Purba and A. Wanto, “Prediksi Jumlah Nilai Impor Sumatera Utara Menurut Negara Asal Menggunakan Algoritma Backpropagation,” *Jurnal Teknologi Informasi Techno*, vol. 17, no. 3, pp. 302–311, 2018.
- [35] S. P. Siregar, A. Wanto, and Z. M. Nasution, “Analisis Akurasi Arsitektur JST Berdasarkan Jumlah Penduduk Pada Kabupaten / Kota di Sumatera Utara,” in *Seminar Nasional Sains & Teknologi Informasi (SENSASI)*, 2018, pp. 526–536.
- [36] A. Wanto and A. P. Windarto, “Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation,” *Jurnal & Penelitian Teknik Informatika Sinkron*, vol. 2, no. 2, pp. 37–44, 2019.
- [37] P. Q. Muoi, D. N. Hao, P. Maass, and M. Pidcock, “Descent gradient methods for nonsmooth minimization problems in ill-posed problems,” *Journal of Computational and Applied Mathematics*, pp. 1–26, 2015.

- [38] A. Senov and O. Granichin, "Projective Approximation Based Gradient Descent Modification," *IFAC-PapersOnLine*, vol. 50, no. 1, pp. 3899–3904, 2017.
- [39] B. K. Singh, K. Verma, and A. S. Thoke, "Adaptive gradient descent backpropagation for classification of breast tumors in ultrasound imaging," *Procedia Computer Science*, vol. 46, pp. 1601–1609, 2015.
- [40] B. P. Statistik, "Angka Partisipasi Sekolah (APS) menurut Provinsi, 2011-2017," *Badan Pusat Statistik (BPS) Indonesia*, 2019. [Online]. Available: <https://www.bps.go.id/dynamictable/2015/12/22/1054/angka-partisipasi-sekolah-aps-menurut-provinsi-2011-2017.html>.