



Model berbasis Sistem Kecerdasan Buatan yang Efektif: Analisis Kebijakan bagi Siswa Mengulang

Indra Prasetia^{#1}, Muhammad Noor Hasan Siregar^{*2}, Rusmin Saragih⁻³

[#]Universitas Muhammadiyah Sumatera Utara

Jl. Kapten Muchtar Basri No.3, Glugur Darat II, Kec. Medan Tim., Kota Medan, Sumatera Utara 20238

¹indraprasetia@umsu.ac.id

^{*}Universitas Graha Nusantara, Padangsidempuan, Sumatera Utara

Jl. Dr. Sutomo, Wek I, Padangsidempuan Utara, Kota Padang Sidempuan, Sumatera Utara 22718

²noor.siregar@gmail.com

⁻STMIK Kaputama

Jl. Veteran No.4A, Tangsi, Kec. Binjai Kota, Kota Binjai, Sumatera Utara 20714

³evitha12014@gmail.com

Abstrak— Pendidikan Sekolah Dasar (SD) sangat penting dalam memberikan keterampilan dasar yang dibutuhkan siswa untuk bertahan dalam mengikuti dan memahami kelas-kelas pada jenjang di atasnya sehingga jika pondasi pendidikan SD kuat maka dapat meningkatkan kualitas pendidikan di Indonesia. Tujuan dari penelitian adalah membuat model arsitektur terbaik yang akan digunakan untuk melakukan peramalan pada jumlah siswa mengulang berdasarkan provinsi pada jenjang Sekolah Dasar baik negeri dan swasta dengan model berbasis sistem kecerdasan buatan. Sumber data berasal dari data statistik pendidikan dengan url: <http://statistik.data.kemdikbud.go.id/>. Data terdiri dari 34 provinsi untuk tahun ajaran 2017/2017; 2017/2018; 2018/2019; 2019/2020. Metode solusi yang digunakan adalah *back-propagation* yang merupakan bagian dari sistem kecerdasan buatan dimana dalam menentukan model arsitektur terbaik dilakukan dengan menguji serangkaian arsitektur (2-5-1; 2-10-1; 2-15-1 dan 2-20-1) menggunakan fungsi aktivasi *sigmoid* dan parameter pendukung seperti $performFcn = \text{MSE}$; $goal = 0.001$; $epochs = 10000$; $mc = 0.95$ dan $lr = 0.1$. Hasil menunjukkan *back-propagation* dapat diterapkan untuk melakukan peramalan dengan sistem kecerdasan buatan dengan menghasilkan sebuah model arsitektur terbaik yakni 2-10-1 dengan MSE pelatihan adalah 0.00099299, koefisien korelasi (R) pelatihan adalah 0.976972 pada epoch 81, MSE pengujian adalah 0.001325, koefisien korelasi (R) pengujian dengan akurasi 85%. Fakta baru menyebutkan bahwa akurasi sangat tergantung terhadap banyaknya data. Selain harus memperhatikan MSE, *epoch* dan durasi waktu pelatihan. Diharapkan model arsitektur ini dapat membantu melakukan peramalan terhadap jumlah siswa mengulang pada jenjang Sekolah Dasar sehingga hasil dari peramalan dapat digunakan untuk membuat analisis kebijakan.

Kata kunci— Siswa mengulang, model arsitektur, JST, *back-propagation*, Indonesia, Sekolah Dasar

I. PENDAHULUAN

Sekolah Dasar (SD) merupakan salah satu bentuk satuan pendidikan dasar yang melandasi sekolah menengah atas sebagaimana diatur dalam UU No. 20 Tahun 2003 dan Jenis Pendidikan Pasal 17 (1) [1]. Pendidikan Sekolah Dasar di Indonesia masih sangat memprihatinkan. Padahal pendidikan SD sangat penting dalam memberikan keterampilan dasar yang dibutuhkan siswa untuk bertahan dalam mengikuti dan memahami kelas-kelas pada jenjang di atasnya. Jika memungkinkan untuk memperkuat pondasi pendidikan sejak SD maka beban pada jenjang pendidikan selanjutnya akan berkurang sehingga dapat meningkatkan kualitas pendidikan di Indonesia [2]. Pada prinsipnya pengulangan kelas dapat dilakukan sebagai proses belajar dimana hal ini dibenarkan dalam teori psikologi. Dengan mengadakan pengulangan maka daya tersebut akan berkembang. Daya itu merupakan daya yang melatih, daya mengamati, menanggapi, mengingat, mengkhayal, merasakan, dan berfikir [3]. Pada penelitian ingin dilakukan peramalan terhadap jumlah siswa mengulang berdasarkan provinsi untuk jenjang pendidikan Sekolah Dasar baik negeri dan swasta menggunakan sistem kecerdasan buatan. Hal ini dilakukan untuk dapat membuat kebijakan berdasarkan data peramalan yang dihasilkan. Data yang digunakan berasal dari data statistik pendidikan dengan url: <http://statistik.data.kemdikbud.go.id/>. Analisis peramalan perlu dilakukan mengingat kebanyakan metode statistik untuk peramalan yang digunakan pada saat ini memiliki kelemahan karena data yang digunakan untuk peramalan harus bersifat linear dan hasil tingkat akurasi yang kurang baik [4]. Beberapa metode statistik yang banyak digunakan adalah *Exponential Smoothing* (ES), SARIMA dan ARIMA) [5]–[7]. Untuk mengatasi kelemahan tersebut maka digunakan analisis peramalan dengan memanfaatkan teknik sistem kecerdasan buatan (*artificial intelligence*) [8]. Salah satu teknik yang

digunakan adalah jaringan saraf tiruan (JST) [9] yang dapat menghasilkan hasil yang lebih baik melalui serangkaian pelatihan [10], [11]. Selain itu metode JST juga sangat baik digunakan pada data deret waktu yang bersifat tidak linear (*nonlinear*) yang mana ini tidak dapat diatasi oleh metode statistik [12]. Salah satu metode JST adalah *back-propagation* [13]–[16] yang dipilih untuk meramalkan jumlah siswa mengulang berdasarkan provinsi pada jenjang Sekolah Dasar. Hal ini sejalan dengan penelitian yang akan dikaji yakni dengan menemukan pola arsitektur terbaik dari serangkaian model *back-propagation* yang diuji dengan menggunakan parameter seperti *learning rate* dan arsitektur jaringan. Alasan digunakan metode ini karena menggunakan jaringan *multilayer* yang dapat meminimalkan *error* pada hasil [17] sehingga dapat, menghasilkan model akurasi terbaik [4]. Lebih lanjut penelitian terbaru tentang *back-propagation* adalah [18] tentang pengenalan wajah. Makalah ini membandingkan tiga algoritma yang berbeda dan menguji keakuratan algoritma tersebut *dimana back-propagation* menjadi algoritma terbaik dengan akurasi diatas 85%. Selanjutnya penelitian yang dilakukan [19] tentang pemodelan pemakaian listrik. Makalah ini mengusulkan metode *back-propagation* untuk membuat model konsumsi listrik di kota Kendari Hasil penelitian menyebutkan metode ini dapat diterapkan dengan menghasilkan model arsitektur dengan 10 unit *input layer* dan 4 unit *hidden layer* dengan MSE terkecil 0,000145. Lebih lanjut, hasil penelitian ini diharapkan dapat membantu memberikan informasi tentang peramalan terhadap jumlah siswa mengulang pada periode berikutnya yang tidak dapat diatasi oleh metode statistik yang ada sehingga dapat digunakan untuk membuat analisis kebijakan.

II. METODE PENELITIAN

Pada tahapan ini dijelaskan secara singkat tentang data siswa mengulang, metode *back-propagation* beserta alur kerja yang dituangkan dalam narasi *flowchat* dan pengukuran hasil dari analisis peramalan jumlah siswa mengulang dengan algoritma *back-propagation*.

A. Data jumlah siswa mengulang

Data yang digunakan adalah data dengan subjek jumlah siswa mengulang menurut tingkat pada tiap provinsi dimana penelitian ini fokus pada tingkat jenjang pendidikan Sekolah Dasar. Sumber data dari data statistik pendidikan (<http://statistik.data.kemdikbud.go.id/>). Data yang digunakan adalah data jenjang Sekolah Dasar pada tahun ajaran 2017/2017; 2017/2018; 2018/2019 dan 2019/2020. Data tersebut dapat dilihat pada Tabel 1-4 dan diplotkan pada Gambar 1. Adapun penelitian ini menggunakan bantuan *software* modeling MATLAB R2021a.

TABEL I
JUMLAH SISWA MENGULANG MENURUT PROVINSI (2016/2017)

Provinsi Province	Tingkat / Grade					
	I	II	III	IV	V	VI
Prov. D.K.I Jakarta	1,113	1,000	888	761	582	11
Prov. Jawa Barat	9,155	4,095	3,008	1,642	1,316	68

Provinsi Province	Tingkat / Grade					
	I	II	III	IV	V	VI
Prov. Jawa Tengah	19,870	11,626	10,233	6,981	4,403	54
Prov. D.I. Yogyakarta	999	635	593	475	373	5
Prov. Jawa Timur	13,055	5,708	4,132	2,589	1,743	67
Prov. Aceh	2,032	1,138	968	542	311	17
Prov. Sumatera Utara	7,486	3,725	2,804	1,652	1,243	170
Prov. Sumatera Barat	6,619	4,203	4,108	3,315	2,416	48
Prov. Riau	5,420	2,838	2,221	1,360	892	18
Prov. Jambi	2,721	1,289	909	542	325	15
Prov. Sumatera Selatan	6,393	3,384	2,798	1,539	979	47
Prov. Lampung	5,385	2,420	1,848	1,041	589	14
Prov. Kalimantan Barat	10,304	5,258	4,197	2,824	1,831	30
Prov. Kalimantan Tengah	2,815	1,235	877	580	331	16
Prov. Kalimantan Selatan	4,452	2,066	1,527	862	458	14
Prov. Kalimantan Timur	1,709	1,415	1,051	593	437	6
Prov. Sulawesi Utara	831	418	340	266	235	17
Prov. Sulawesi Tengah	2,848	1,356	1,177	810	558	27
Prov. Sulawesi Selatan	4,531	2,431	2,140	1,267	1,100	228
Prov. Sulawesi Tenggara	2,000	1,168	1,213	847	679	128
Prov. Maluku	2,177	784	634	400	248	30
Prov. Bali	1,000	562	392	168	69	2
Prov. NTB	2,789	1,287	1,112	618	503	52
Prov. NTT	12,548	6,618	5,662	3,876	2,572	52
Prov. Papua	4,866	2,178	2,025	1,363	1,511	227
Prov. Bengkulu	1,802	898	717	459	349	0
Prov. Maluku Utara	1,228	508	437	288	238	30
Prov. Banten	5,116	2,411	1,677	724	467	11
Prov. Kep. Bangka	1,540	940	978	633	451	0
Prov. Gorontalo	1,725	978	759	543	461	38
Prov. Kepulauan Riau	1,019	573	456	358	214	1
Prov. Papua Barat	1,860	841	745	451	248	25
Prov. Sulawesi Barat	871	555	545	317	249	17
Prov. Kalimantan Utara	693	275	225	123	114	2

TABEL II
JUMLAH SISWA MENGULANG MENURUT PROVINSI (2017/2018)

Provinsi Province	Tingkat / Grade					
	I	II	III	IV	V	VI
Prov. D.K.I Jakarta	1,229	960	867	702	620	8
Prov. Jawa Barat	8,720	3,645	2,439	1,499	1,338	22
Prov. Jawa Tengah	20,865	11,868	9,827	6,592	4,256	32
Prov. D.I. Yogyakarta	898	602	521	321	280	2
Prov. Jawa Timur	13,481	5,224	3,812	2,463	1,929	62
Prov. Aceh	2,400	993	906	578	344	25
Prov. Sumatera Utara	7,522	3,342	2,483	1,526	1,099	150
Prov. Sumatera Barat	6,964	4,280	4,168	3,339	2,365	21
Prov. Riau	5,423	2,672	2,124	1,241	839	21
Prov. Jambi	2,827	1,187	950	470	329	15
Prov. Sumatera Selatan	7,470	3,433	2,769	1,625	1,047	39
Prov. Lampung	5,460	2,440	1,815	994	688	10
Prov. Kalimantan Barat	11,056	5,444	4,336	2,785	2,037	26
Prov. Kalimantan Tengah	3,310	1,309	1,056	660	360	16
Prov. Kalimantan Selatan	4,638	2,046	1,532	740	394	14
Prov. Kalimantan Timur	2,883	1,253	999	583	340	5
Prov. Sulawesi Utara	1,179	485	429	259	272	10
Prov. Sulawesi Tengah	3,138	1,459	1,276	758	619	51
Prov. Sulawesi Selatan	4,912	2,186	1,941	1,162	1,064	181
Prov. Sulawesi Tenggara	2,093	1,042	1,067	837	613	142
Prov. Maluku	2,559	931	689	467	332	41
Prov. Bali	991	463	337	131	62	1
Prov. NTB	3,439	1,402	986	647	551	60
Prov. NTT	14,010	6,183	5,230	3,871	2,770	59
Prov. Papua	6,446	2,725	2,612	1,903	2,450	395
Prov. Bengkulu	1,817	882	722	441	350	7
Prov. Maluku Utara	1,413	451	385	269	217	46
Prov. Banten	4,967	2,052	1,485	589	408	23
Prov. Kep. Bangka	1,712	950	896	689	409	1
Prov. Gorontalo	1,984	899	817	577	531	51
Prov. Kepulauan Riau	1,105	554	478	372	210	5
Prov. Papua Barat	2,641	1,044	986	665	590	61
Prov. Sulawesi Barat	1,107	566	557	368	318	32
Prov. Kalimantan Utara	834	293	215	163	109	6

TABEL III
JUMLAH SISWA MENGULANG MENURUT PROVINSI (2018/2019)

Provinsi Province	Tingkat / Grade					
	I	II	III	IV	V	VI
Prov. D.K.I Jakarta	1,550	903	902	663	743	35
Prov. Jawa Barat	7,516	3,454	2,363	1,347	1,647	56
Prov. Jawa Tengah	18,413	10,693	8,757	5,532	3,820	29
Prov. D.I. Yogyakarta	741	539	465	281	259	3
Prov. Jawa Timur	11,314	4,559	3,145	1,965	1,942	63
Prov. Aceh	2,002	926	776	525	485	32
Prov. Sumatera Utara	6,558	3,116	2,476	1,392	1,244	101
Prov. Sumatera Barat	6,770	4,193	3,830	2,732	2,193	7
Prov. Riau	5,504	2,554	2,029	1,114	952	22
Prov. Jambi	2,801	1,096	864	471	348	20

Provinsi Province	Tingkat / Grade					
	I	II	III	IV	V	VI
Prov. Sumatera Selatan	7,060	3,696	2,902	1,616	1,269	47
Prov. Lampung	4,686	2,232	1,800	821	701	28
Prov. Kalimantan Barat	10,339	4,927	3,924	2,559	1,839	52
Prov. Kalimantan Tengah	3,139	1,270	977	455	386	25
Prov. Kalimantan Selatan	4,473	1,810	1,271	554	377	6
Prov. Kalimantan Timur	2,409	1,183	861	506	387	14
Prov. Sulawesi Utara	1,243	425	467	324	420	14
Prov. Sulawesi Tengah	2,824	1,194	1,000	563	573	30
Prov. Sulawesi Selatan	4,007	1,918	1,635	908	1,145	151
Prov. Sulawesi Tenggara	1,600	987	977	695	875	111
Prov. Maluku	2,148	744	532	370	426	14
Prov. Bali	795	412	287	114	69	6
Prov. NTB	2,998	1,125	917	522	521	19
Prov. NTT	12,416	5,669	4,701	3,500	2,876	73
Prov. Papua	6,623	3,279	2,621	2,168	3,507	308
Prov. Bengkulu	1,725	916	649	386	352	17
Prov. Maluku Utara	1,362	509	445	282	472	81
Prov. Banten	4,135	1,837	1,311	570	583	16
Prov. Kep. Bangka Belitung	1,678	906	874	590	468	2
Prov. Gorontalo	1,660	717	671	466	453	18
Prov. Kepulauan Riau	1,035	522	455	288	219	1
Prov. Papua Barat	2,421	1,084	980	827	1,081	37
Prov. Sulawesi Barat	944	496	511	324	375	26
Prov. Kalimantan Utara	619	254	174	119	74	1

TABEL IV
JUMLAH SISWA MENGLANG MENURUT PROVINSI (2019/2020)


Provinsi Province	Tingkat / Grade					
	I	II	III	IV	V	VI
Prov. D.K.I Jakarta	1,426	780	655	571	705	6
Prov. Jawa Barat	6,201	2,572	1,906	1,153	1,582	12
Prov. Jawa Tengah	15,085	8,240	6,322	3,711	2,813	21
Prov. D.I. Yogyakarta	544	414	350	274	195	1
Prov. Jawa Timur	8,348	3,145	2,309	1,627	1,721	4
Prov. Aceh	1,794	757	648	432	433	5
Prov. Sumatera Utara	5,597	2,649	2,030	1,147	1,508	14
Prov. Sumatera Barat	5,745	3,265	2,911	2,297	1,637	6
Prov. Riau	4,984	2,102	1,545	977	878	1
Prov. Jambi	2,553	887	589	310	369	3
Prov. Sumatera Selatan	6,004	2,743	2,174	1,196	1,426	11
Prov. Lampung	3,666	1,819	1,249	717	607	13
Prov. Kalimantan Barat	9,416	4,322	3,173	2,018	1,833	6
Prov. Kalimantan Tengah	2,647	1,071	777	492	428	32
Prov. Kalimantan Selatan	3,884	1,469	1,076	461	313	0
Prov. Kalimantan Timur	1,951	887	685	400	312	5
Prov. Sulawesi Utara	897	457	359	228	466	0
Prov. Sulawesi Tengah	2,061	963	774	387	568	13
Prov. Sulawesi Selatan	3,519	1,520	1,334	809	920	39
Prov. Sulawesi Tenggara	1,295	671	749	520	779	18
Prov. Maluku	1,828	569	459	308	557	2
Prov. Bali	627	321	196	84	50	0
Prov. NTB	2,214	816	768	423	638	1
Prov. NTT	10,301	4,124	3,441	2,587	2,387	13
Prov. Papua	5,214	2,208	2,143	1,949	4,038	99
Prov. Bengkulu	1,554	709	521	379	358	1
Prov. Maluku Utara	1,035	399	260	192	452	19
Prov. Banten	3,327	1,415	957	481	643	8
Prov. Kep. Bangka Belitung	1,463	758	611	450	284	1
Prov. Gorontalo	1,455	583	440	352	338	5
Prov. Kepulauan Riau	913	465	365	273	276	1
Prov. Papua Barat	2,134	869	750	600	1,360	20
Prov. Sulawesi Barat	785	442	448	251	369	7
Prov. Kalimantan Utara	546	192	129	69	72	0

Pada Tabel 1-4 data akan diolah dengan menjumlahkan total keseluruhan dari tingkat I-VI berdasarkan provinsi. Data tabel jumlah siswa mengulang berdasarkan provinsi yang sudah diolah dapat dilihat pada Tabel 5.

TABEL V
JUMLAH SISWA MENGLANG MENURUT PROVINSI

Provinsi	2016-2017	2017-2018	2018-2019	2019-2020
Prov. D.K.I Jakarta	4355	4386	4796	4143
Prov. Jawa Barat	19284	17663	16383	13426
Prov. Jawa Tengah	53167	53440	47244	36192
Prov. D.I. Yogyakarta	3080	2624	2288	1778
Prov. Jawa Timur	27294	26971	22988	17154
Prov. Aceh	5008	5246	4746	4069
Prov. Sumatera Utara	17080	16122	14887	12945
Prov. Sumatera Barat	20709	21137	19725	15861
Prov. Riau	12749	12320	12175	10487
Prov. Jambi	5801	5778	5600	4711
Prov. Sumatera Selatan	15140	16383	16590	13554

Provinsi	2016-2017	2017-2018	2018-2019	2019-2020
Prov. Lampung	11297	11407	10268	8071
Prov. Kalimantan Barat	24444	25684	23640	20768
Prov. Kalimantan Tengah	5854	6711	6252	5447
Prov. Kalimantan Selatan	9379	9364	8491	7203
Prov. Kalimantan Timur	5211	6063	5360	4240
Prov. Sulawesi Utara	2107	2634	2893	2407
Prov. Sulawesi Tengah	6776	7301	6184	4766
Prov. Sulawesi Selatan	11697	11446	9764	8141
Prov. Sulawesi Tenggara	6035	5794	5245	4032
Prov. Maluku	4273	5019	4234	3723
Prov. Bali	2193	1985	1683	1278
Prov. NTB	6361	7085	6102	4860
Prov. NTT	31328	32123	29235	22853
Prov. Papua	12170	16531	18506	15651
Prov. Bengkulu	4225	4219	4045	3522
Prov. Maluku Utara	2729	2781	3151	2357
Prov. Banten	10406	9524	8452	6831
Prov. Kep. Bangka	4542	4657	4518	3567
Prov. Gorontalo	4504	4859	3985	3173
Prov. Kepulauan Riau	2621	2724	2520	2293
Prov. Papua Barat	4170	5987	6430	5733
Prov. Sulawesi Barat	2554	2948	2676	2302
Prov. Kalimantan Utara	1432	1620	1241	1008



Gambar. 1 Plot data jumlah siswa mengulang berdasarkan provinsi pada jenjang Sekolah Dasar

Sebelum proses peramalan dilakukan, maka proses normalisasi jumlah data siswa mengulang dilakukan dengan mengubah nilai kedalam ordo [0-1]. Hal ini bertujuan mempercepat proses pelatihan algoritma *back-propagation* tanpa mengurangi nilai data sebenarnya dengan menggunakan fungsi aktivasi yang digunakan adalah *sigmoid*. Berikut formula yang digunakan untuk menormalisasikan data.

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

Dimana nilai X' merupakan nilai hasil normalisasi data, X merupakan nilai yang akan dinormalisasi, a merupakan nilai maksimum dari seluruh data penelitian, b merupakan nilai minimum dari seluruh data penelitian, 0,8 dan 0,1 adalah bilangan ketetapan (konstanta).

TABEL VI
DATA NORMALISASI

Provinsi	2016-2017	2017-2018	2018-2019	2019-2020
Prov. D.K.I Jakarta	0.1511	0.1515	0.1578	0.1478
Prov. Jawa Barat	0.3789	0.3541	0.3346	0.2895
Prov. Jawa Tengah	0.8958	0.9000	0.8055	0.6368
Prov. D.I. Yogyakarta	0.1316	0.1247	0.1195	0.1117
Prov. Jawa Timur	0.5011	0.4961	0.4354	0.3464
Prov. Aceh	0.1610	0.1647	0.1570	0.1467
Prov. Sumatera Utara	0.3452	0.3306	0.3118	0.2821
Prov. Sumatera Barat	0.4006	0.4071	0.3856	0.3266
Prov. Riau	0.2791	0.2726	0.2704	0.2446
Prov. Jambi	0.1731	0.1728	0.1701	0.1565
Prov. Sumatera Selatan	0.3156	0.3346	0.3377	0.2914
Prov. Lampung	0.2570	0.2587	0.2413	0.2078
Prov. Kalimantan Barat	0.4576	0.4765	0.4453	0.4015
Prov. Kalimantan Tengah	0.1739	0.1870	0.1800	0.1677


Provinsi	2016-2017	2017-2018	2018-2019	2019-2020
Prov. Kalimantan Selatan	0.2277	0.2275	0.2142	0.1945
Prov. Kalimantan Timur	0.1641	0.1771	0.1664	0.1493
Prov. Sulawesi Utara	0.1168	0.1248	0.1288	0.1213
Prov. Sulawesi Tengah	0.1880	0.1960	0.1790	0.1573
Prov. Sulawesi Selatan	0.2631	0.2593	0.2336	0.2088
Prov. Sulawesi Tenggara	0.1767	0.1730	0.1646	0.1461
Prov. Maluku	0.1498	0.1612	0.1492	0.1414
Prov. Bali	0.1181	0.1149	0.1103	0.1041
Prov. NTB	0.1817	0.1927	0.1777	0.1588
Prov. NTT	0.5626	0.5747	0.5307	0.4333
Prov. Papua	0.2703	0.3368	0.3670	0.3234
Prov. Bengkulu	0.1491	0.1490	0.1463	0.1384
Prov. Maluku Utara	0.1263	0.1271	0.1327	0.1206
Prov. Banten	0.2434	0.2299	0.2136	0.1888
Prov. Kep. Bangka	0.1539	0.1557	0.1536	0.1390
Prov. Gorontalo	0.1533	0.1588	0.1454	0.1330
Prov. Kepulauan Riau	0.1246	0.1262	0.1231	0.1196
Prov. Papua Barat	0.1482	0.1760	0.1827	0.1721
Prov. Sulawesi Barat	0.1236	0.1296	0.1255	0.1197
Prov. Kalimantan Utara	0.1065	0.1093	0.1036	0.1000

B. Metode Back-propagation

Back-propagation merupakan algoritma sistematis untuk pelatihan multilayer JST dengan melakukan pembelajaran untuk mengurangi tingkat error dengan penyesuaian bobot (w) berdasarkan perbedaan keluaran (output) dan tujuan yang diinginkan [12]. Back-propagation menggunakan beberapa level lapisan. Masing-masing lapisan tersebut sebagai berikut:

- a) *Input layer* - lapisan yang mentransfer data ke sistem pada lapisan berikutnya untuk diproses nanti.
- b) *Output layer* - lapisan terakhir dari neuron yang menghasilkan output.
- c) *Hidden layer* - lapisan antara input dan output yang memiliki nilai bobot untuk menghasilkan output melalui fungsi aktivasi [20].

Dalam algoritma back-propagation digunakan fungsi aktivasi sigmoid biner, karena output yang diharapkan bernilai [0 1]. Berikut adalah gambar jaringan arsitektur algoritma back-propagation seperti yang ditunjukkan pada Gambar 2.



Gambar. 2 Jaringan arsitektur algoritma back-propagation

Berikut adalah langkah-langkah penyelesaian algoritma back-propagation yang dibuat dalam flowchat seperti yang ditunjukkan Gambar 3.

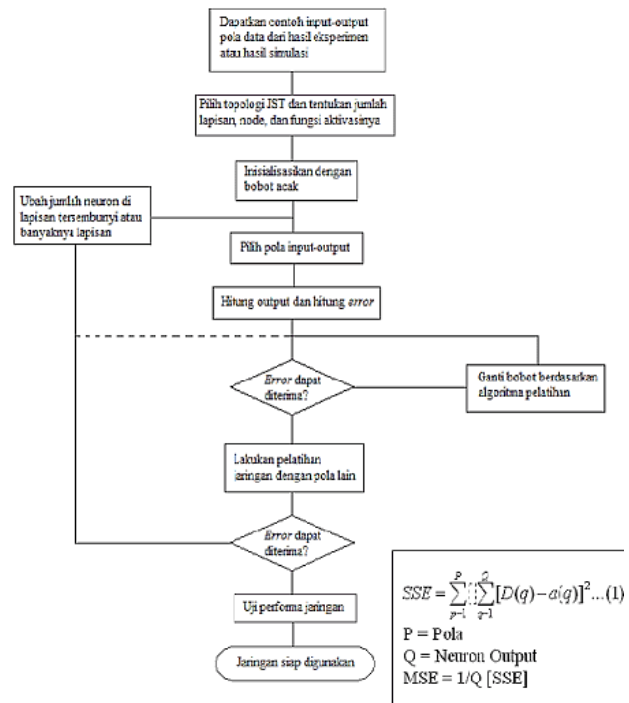
C. Pengukuran hasil simulasi peramalan

Prediksi pengukuran metode bertujuan untuk mendapatkan nilai terbaik antara nilai asli dan nilai prediksi. Dalam hal ini terdapat beberapa metode statistik untuk mengukur model prediksi seperti *normalize mean square error* (NMSE), *root mean squared error* (RMSE), *mean square error* (MSE) dan *mean absolute error* (MAE).

Metode pengukuran yang digunakan pada penelitian adalah MSE dengan formula

$$MSE = \frac{\sum_{t=1}^n (At - Ft)^2}{n} \tag{2}$$

Dimana At merupakan nilai observasi data; (At - Ft)² merupakan nilai hasil peramalan; n merupakan nilai dari jumlah siswa mengulang.



Gambar. 3 Flowchart Algoritma Back-propagation

III. HASIL DAN PEMBAHASAN

Sebelum dilakukan proses pelatihan dan pengujian pada serangkaian model arsitektur back-propagation, terlebih dahulu melakukan penetapan input dan output. Dimana yang menjadi variabel input adalah total dari jumlah siswa mengulang berdasarkan provinsi untuk setiap tahun ajaran (Tabel 5) dan variabel output adalah penetapan model arsitektur terbaik pada kasus jumlah siswa mengulang dengan cara menentukan tingkat error dari suatu target. Semakin kecil nilai error maka pola arsitektur terbaik semakin baik dengan range (0,001 - 0,02). Dalam penentuan model arsitektur terbaik, proses dibagi dua tahap yakni tahapan pelatihan model dan tahapan pengujian model. Model yang diuji pada penelitian ini adalah 2-5-1; 2-10-1; 2-15-1 dan 2-20-1 dengan menggunakan bantuan software modeling MATLAB R2021a. Tahapan tersebut menggunakan data yang sudah dinormalisasi (Tabel 6) dimana tahapan pelatihan menggunakan data (input: 2016/2017 (x1); 2017/2018 (x2) dan output: 2018/2019 (Y)) serta tahapan pengujian menggunakan data (input: 2017/2018 (x1); 2018/2019 (x2) dan output: 2019/2020 (Y)) seperti yang ditunjukkan pada Tabel 7 dan 8.

TABEL VII
DATA PELATIHAN

No	Provinsi	2016-2017 (X1)	2017-2018 (X2)	2018-2019 (Y)
1	Prov. D.K.I Jakarta	0.1511	0.1515	0.1578
2	Prov. Jawa Barat	0.3789	0.3541	0.3346
3	Prov. Jawa Tengah	0.8958	0.9000	0.8055
4	Prov. D.I. Yogyakarta	0.1316	0.1247	0.1195
5	Prov. Jawa Timur	0.5011	0.4961	0.4354
6	Prov. Aceh	0.1610	0.1647	0.1570
7	Prov. Sumatera Utara	0.3452	0.3306	0.3118
8	Prov. Sumatera Barat	0.4006	0.4071	0.3856
9	Prov. Riau	0.2791	0.2726	0.2704
10	Prov. Jambi	0.1731	0.1728	0.1701
11	Prov. Sumatera Selatan	0.3156	0.3346	0.3377
12	Prov. Lampung	0.2570	0.2587	0.2413
13	Prov. Kalimantan Barat	0.4576	0.4765	0.4453
14	Prov. Kalimantan Tengah	0.1739	0.1870	0.1800
15	Prov. Kalimantan Selatan	0.2277	0.2275	0.2142
16	Prov. Kalimantan Timur	0.1641	0.1771	0.1664
17	Prov. Sulawesi Utara	0.1168	0.1248	0.1288
18	Prov. Sulawesi Tengah	0.1880	0.1960	0.1790
19	Prov. Sulawesi Selatan	0.2631	0.2593	0.2336
20	Prov. Sulawesi Tenggara	0.1767	0.1730	0.1646
21	Prov. Maluku	0.1498	0.1612	0.1492
22	Prov. Bali	0.1181	0.1149	0.1103
23	Prov. Nusa Tenggara Barat	0.1817	0.1927	0.1777
24	Prov. Nusa Tenggara Timur	0.5626	0.5747	0.5307
25	Prov. Papua	0.2703	0.3368	0.3670
26	Prov. Bengkulu	0.1491	0.1490	0.1463
27	Prov. Maluku Utara	0.1263	0.1271	0.1327
28	Prov. Banten	0.2434	0.2299	0.2136
29	Prov. Kep. Bangka Belitung	0.1539	0.1557	0.1536
30	Prov. Gorontalo	0.1533	0.1588	0.1454
31	Prov. Kepulauan Riau	0.1246	0.1262	0.1231
32	Prov. Papua Barat	0.1482	0.1760	0.1827
33	Prov. Sulawesi Barat	0.1236	0.1296	0.1255
34	Prov. Kalimantan Utara	0.1065	0.1093	0.1036

TABEL VIII
DATA PENGUJIAN

No	Provinsi	2017-2018 (X1)	2018-2019 (X2)	2019-2020 (Y)
1	Prov. D.K.I Jakarta	0.1515	0.1578	0.1478
2	Prov. Jawa Barat	0.3541	0.3346	0.2895
3	Prov. Jawa Tengah	0.9000	0.8055	0.6368
4	Prov. D.I. Yogyakarta	0.1247	0.1195	0.1117
5	Prov. Jawa Timur	0.4961	0.4354	0.3464
6	Prov. Aceh	0.1647	0.1570	0.1467
7	Prov. Sumatera Utara	0.3306	0.3118	0.2821
8	Prov. Sumatera Barat	0.4071	0.3856	0.3266
9	Prov. Riau	0.2726	0.2704	0.2446
10	Prov. Jambi	0.1728	0.1701	0.1565
11	Prov. Sumatera Selatan	0.3346	0.3377	0.2914
12	Prov. Lampung	0.2587	0.2413	0.2078
13	Prov. Kalimantan Barat	0.4765	0.4453	0.4015
14	Prov. Kalimantan Tengah	0.1870	0.1800	0.1677
15	Prov. Kalimantan Selatan	0.2275	0.2142	0.1945
16	Prov. Kalimantan Timur	0.1771	0.1664	0.1493
17	Prov. Sulawesi Utara	0.1248	0.1288	0.1213
18	Prov. Sulawesi Tengah	0.1960	0.1790	0.1573
19	Prov. Sulawesi Selatan	0.2593	0.2336	0.2088
20	Prov. Sulawesi Tenggara	0.1730	0.1646	0.1461
21	Prov. Maluku	0.1612	0.1492	0.1414
22	Prov. Bali	0.1149	0.1103	0.1041
23	Prov. Nusa Tenggara Barat	0.1927	0.1777	0.1588
24	Prov. Nusa Tenggara Timur	0.5747	0.5307	0.4333
25	Prov. Papua	0.3368	0.3670	0.3234
26	Prov. Bengkulu	0.1490	0.1463	0.1384
27	Prov. Maluku Utara	0.1271	0.1327	0.1206
28	Prov. Banten	0.2299	0.2136	0.1888
29	Prov. Kep. Bangka Belitung	0.1557	0.1536	0.1390
30	Prov. Gorontalo	0.1588	0.1454	0.1330
31	Prov. Kepulauan Riau	0.1231	0.1231	0.1196
32	Prov. Papua Barat	0.1760	0.1827	0.1721
33	Prov. Sulawesi Barat	0.1296	0.1255	0.1197
34	Prov. Kalimantan Utara	0.1093	0.1036	0.1000

Kemudian melakukan pelatihan dilakukan beberapa pemilihan nilai parameter untuk memperoleh hasil yang optimal. Adapun nilai parameter yang digunakan dapat dilihat pada Gambar 4.

```

a) net=newff(minmax(P), [Hidden,Target], {'tansig',
'logsig'}, 'traingdx');
b) bobot_hidden = net_keluaran.IW(1,1);
c) bobot_keluaran = net_keluaran.IW(2,1);
d) bias_hidden = net_keluaran.b(1,1);
e) bias_keluaran = net_keluaran.b(2,1);
f) net.performFcn = 'mse';
g) net.trainParam.goal = 0.001;
h) net.trainParam.show = 20;
i) net.trainParam.epochs = 10000;
j) net.trainParam.mc = 0.95;
k) net.trainParam.lr = 0.1;
    
```

Gambar. 4 Nilai parameter

Dalam eksperimen ini, arsitektur *back-propagation* yang digunakan terdiri dari satu lapisan *hidden layer* (5; 15; 15; 20) dengan fungsi aktivasi fungsi aktivasi 'tansig' (*input ke hidden layer*) dan 'logsig' (*hidden ke output layer*). Sedangkan algoritma pelatihan yang digunakan untuk semua arsitektur adalah 'traingdx'. Dalam pengujian ini, metode statistik MSE digunakan untuk membandingkan nilai asli dan nilai hasil peramalan.

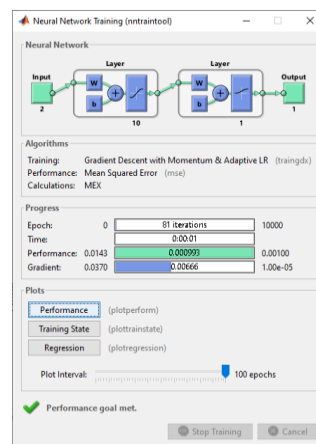
TABEL IX
HASIL PELATIHAN ALGORITMA BACK-PROPAGATION

No	Model Arsitektur	Pelatihan		
		Mean Square Error (MSE)	Koefisien korelasi (R)	Epoch
1	2-5-1	0.00099424	0.97813	132
2	2-10-1	0.00099299	0.976972	81
3	2-15-1	0.00097013	0.97817	87
4	2-20-1	0.00099062	0.97873	135

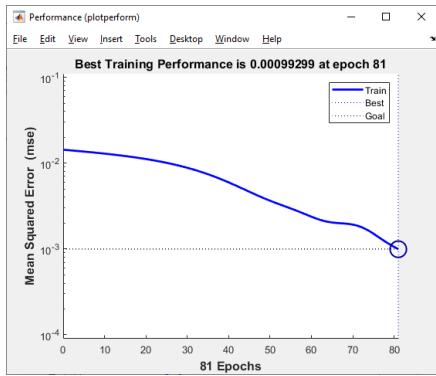
TABEL X
HASIL PENGUJIAN ALGORITMA BACK-PROPAGATION

No	Model Arsitektur	Pengujian		
		Mean Square Error (MSE)	Koefisien korelasi (R)	Akurasi
1	2-5-1	0.0010664	0.96035	68%
2	2-10-1	0.001325	0.96589	85%
3	2-15-1	0.00069132	0.9799	76%
4	2-20-1	0.002116	0.98417	74%

Dari Tabel 9 dan 10 dijelaskan bahwa model arsitektur 2-10-1 merupakan model terbaik dengan akurasi pengujian sebesar 80%. Berikut hasil lengkap dari model arsitektur terbaik menggunakan *software* MATLAB R2021a seperti yang ditunjukkan Gambar 5 dan 6 berikut.




Gambar. 5 GUI dari pelatihan model arsitektur terbaik dengan algoritma *back-propagation*



Gambar. 6 Hasil pelatihan model arsitektur terbaik dengan algoritma *back-propagation* dimana *error goal* (*MSE*) sebesar 0.00099299 dicapai pada epoch yang ke-81

Pada Gambar 5 tampilan tersebut ditunjukkan bahwa target *error* (*mse*) tercapai pada epoch ke-81. *Error* (*mse*) yang dihasilkan pada setiap *epoch* dapat dilihat dengan meng-klik tombol ‘*performance*’ sehingga muncul tampilan seperti yang ditunjukkan pada Gambar 6. Sedangkan koefisien korelasi hasil pelatihan dapat dilihat dengan meng-klik tombol ‘*regression*’ sehingga muncul tampilan seperti yang ditunjukkan pada Gambar 7.

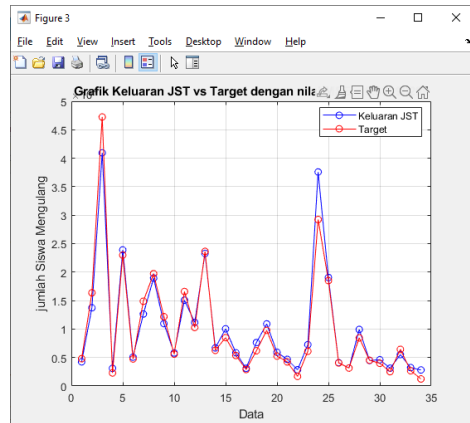


Gambar. 7 Koefisien korelasi R yang dihasilkan adalah sebesar 0,97692 dengan algoritma *back-propagation*

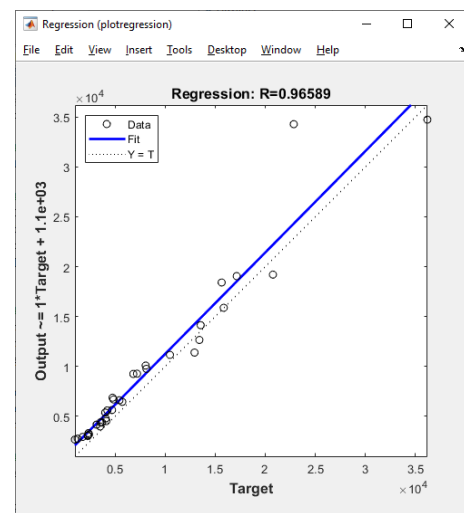
Pada Gambar 7 nilai koefisien korelasi sebesar 0.97692 menunjukkan bahwa akurasi hasil proses pelatihan sangat baik. Berikut adalah grafik keluaran JST vs target seperti yang ditunjukkan pada Gambar 8.

Berdasarkan Gambar 8 pada nilai koefisien korelasi dan nilai MSE (*Mean Square Error*) yang diperoleh pada proses pelatihan tersebut sangat baik. Berikut hasil koefisien korelasi hasil pengujian dan perbandingan nilai luaran grafik keluaran JST vs target hasil pengujian seperti yang ditunjukkan pada Gambar 9 dan 10.

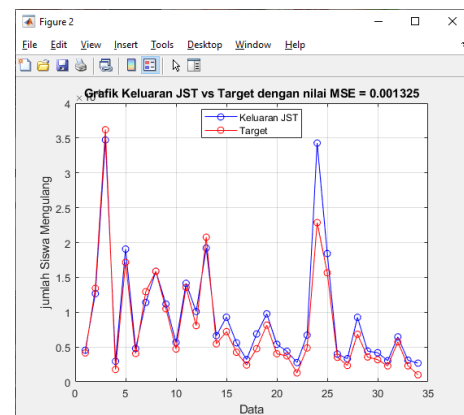
Pada Gambar 10 dijelaskan bahwa nilai koefisien korelasi dan nilai MSE yang dihasilkan pada proses pengujian menunjukkan bahwa algoritma *back-propagation* cukup baik untuk meramal jumlah siswa mengulang. Berikut adalah perbandingan dari data target dan *error* yang dihasilkan oleh model arsitektur terbaik 2-10-1 seperti yang ditunjukkan pada Tabel 11.



Gambar. 8 Hasil nilai koefisien korelasi dan nilai yang diperoleh pada proses pelatihan dalam meramal jumlah siswa mengulang adalah sangat baik.



Gambar. 9 Hasil proses pengujian jaringan yang menghasilkan koefisien korelasi sebesar 0,96589 pada model arsitektur 2-10-1



Gambar. 10 Hasil pengujian dari grafik keluaran JST dan nilai MSE

TABEL X
PERBANDINGAN DATA TARGET DAN ERROR PADA MODEL ARSITEKTUR TERBAIK

No	Provinsi	Target	Error	SSE	Prediksi
1	Prov. D.K.I Jakarta	0.1478	0.0060	0.00003545	1

No	Provinsi	Target	Error	SSE	Prediksi
2	Prov. Jawa Barat	0.2895	-0.0117	0.00013747	1
3	Prov. Jawa Tengah	0.6368	-0.0223	0.00049941	1
4	Prov. D.I. Yogyakarta	0.1117	0.0178	0.00031832	1
5	Prov. Jawa Timur	0.3464	0.0290	0.00084118	1
6	Prov. Aceh	0.1467	0.0110	0.00012080	1
7	Prov. Sumatera Utara	0.2821	-0.0236	0.00055835	1
8	Prov. Sumatera Barat	0.3266	0.0003	0.00000009	1
9	Prov. Riau	0.2446	0.0103	0.00010596	1
10	Prov. Jambi	0.1565	0.0143	0.00020340	1
11	Prov. Sumatera Selatan	0.2914	0.0089	0.00007976	1
12	Prov. Lampung	0.2078	0.0308	0.00095088	0
13	Prov. Kalimantan Barat	0.4015	-0.0238	0.00056806	1
14	Prov. Kalimantan Tengah	0.1677	0.0179	0.00031946	1
15	Prov. Kalimantan Selatan	0.1945	0.0317	0.00100293	0
16	Prov. Kalimantan Timur	0.1493	0.0208	0.00043299	1
17	Prov. Sulawesi Utara	0.1213	0.0121	0.00014573	1
18	Prov. Sulawesi Tengah	0.1573	0.0322	0.00103537	0
19	Prov. Sulawesi Selatan	0.2088	0.0248	0.00061560	1
20	Prov. Sulawesi Tenggara	0.1461	0.0207	0.00042653	1
21	Prov. Maluku	0.1414	0.0100	0.00010002	1
22	Prov. Bali	0.1041	0.0227	0.00051682	1
23	Prov. Nusa Tenggara Barat	0.1588	0.0280	0.00078535	1
24	Prov. Nusa Tenggara Timur	0.4333	0.1743	0.03037607	1
25	Prov. Papua	0.3234	0.0422	0.00178103	0
26	Prov. Bengkulu	0.1384	0.0072	0.00005154	1
27	Prov. Maluku Utara	0.1206	0.0147	0.00021693	1
28	Prov. Banten	0.1888	0.0370	0.00136763	0
29	Prov. Kepulauan Bangka	0.1390	0.0130	0.00016779	1
30	Prov. Gorontalo	0.1330	0.0153	0.00023378	1
31	Prov. Kepulauan Riau	0.1196	0.0113	0.00012874	1
32	Prov. Papua Barat	0.1721	0.0111	0.00012288	1
33	Prov. Sulawesi Barat	0.1197	0.0123	0.00015145	1
34	Prov. Kalimantan Utara	0.1000	0.0255	0.00065229	1
		MSE		0.00132500	85%

IV. KESIMPULAN

Paper ini mempresentasikan penerapan model berbasis sistem kecerdasan buatan dalam melakukan peramalan jumlah siswa mengulang berdasarkan provinsi pada jenjang Sekolah Dasar. Metode back-propagation yang menjadi solusi dari permasalahan tersebut dapat menghasilkan model arsitektur yang dapat digunakan dalam melakukan peramalan pada jumlah siswa mengulang sehingga hasil dari peramalan dapat digunakan untuk membuat analisis kebijakan. Fakta baru menyebutkan bahwa akurasi sangat tergantung terhadap banyaknya data dalam melakukan peramalan. Kedepan penelitian ini dapat dikombinasikan dengan algoritma lain untuk mengoptimalkan hasil seperti *Particle Swarm Optimization* (PSO) dan algoritma genetika (GA).

REFERENSI

[1] B. P. D. P. D. P. K. P. D. Kebudayaan, *Potret mengulang kelas di Sekolah Dasar*. Jakarta: Pusat Penelitian Kebijakan, Badan Penelitian dan Pengembangan dan Perbukuan, Kementerian Pendidikan dan Kebudayaan Redaksi:, 2020.

[2] Herwanto, "Wajib Belajar (Wajar) Sembilan Tahun Dalam Perspektif Peningkatan Mutu Pendidikan Dasar," *Perspektif Ilmu Pendidikan*, vol. 16, no. 8, pp. 77–86, 2007.

[3] S. Suryana, *Permasalahan Mutu Pendidikan Dalam Perspektif Pembangunan Pendidikan*, vol. 2, no. 1. 2017.

[4] H. Haviluddin, Z. Arifin, A. H. Kridalaksana, and D. Cahyadi, "Prediksi Kedatangan Turis Asing ke Indonesia Menggunakan Backpropagation Neural Networks," *Jurnal Teknologi dan Sistem Komputer*, vol. 4, no. 4, p. 485, 2016, doi: 10.14710/jtsiskom.4.4.2016.485-490.

[5] X. Sun, W. Sun, J. Wang, Y. Zhang, and Y. Gao, "Using a GreyMarkov model optimized by Cuckoo search algorithm to forecast the annual foreign tourist arrivals to China," *Tourism Management*, vol. 52, pp. 369–379, 2016.

[6] H. Hassani, A. Webster, E. S. Silva, and S. Heravi, "Forecasting U.S. Tourist arrivals using optimal Singular Spectrum Analysis," *Tourism Management*, vol. 46, pp. 322–335, 2015.

[7] W. Lijuan and C. Guohua, "Seasonal SVR with FOA algorithm for single-step and multi-step ahead forecasting in monthly inbound tourist flow," *Knowledge-Based Systems*, vol. 110, 2016.

[8] B. Fachri, A. P. Windarto, and I. Parinduri, "Penerapan Backpropagation dan Analisis Sensitivitas pada Prediksi Indikator Terpenting Perusahaan Listrik," *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 5, no. 2, p. 202, 2019, doi: 10.26418/jp.v5i2.31650.

[9] 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, 2019, doi: 10.26877/jiu.v4i2.2423.

[10] Y. Aprizal, R. I. Zainal, and A. Afriyudi, "Perbandingan Metode Backpropagation dan Learning Vector Quantization (LVQ) Dalam Menggali Potensi Mahasiswa Baru di STMIK PalComTech," *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 18, no. 2, pp. 294–301, 2019, doi: 10.30812/matrik.v18i2.387.

[11] B. Poerwanto and F. Fajriani, "Resilient Backpropagation Neural Network on Prediction of Poverty Levels in South Sulawesi," *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 20, no. 1, pp. 11–18, 2020, doi: 10.30812/matrik.v20i1.726.

[12] Budiharjo, T. Soemartono, A. P. Windarto, and T. Herawan, "Predicting School Participation in Indonesia using Back-Propagation Algorithm Model," *International Journal of Control and Automation*, vol. 11, no. 11, pp. 57–68, 2018.

[13] A. P. Windarto, J. Na, and A. Wanto, "Bagian 2 : Model Arsitektur Neural Network dengan Kombinasi K- Medoids dan Backpropagation pada kasus Pandemi COVID-19 di Indonesia," *Jurnal Media Informatika Budidarma*, vol. 4, no. 4, pp. 1175–1180, 2020, doi: 10.30865/mib.v4i4.2505.

[14] 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. 1, 2018, doi: 10.1088/1757-899X/420/1/012087.

[15] Budiharjo, T. Soemartono, A. P. Windarto, and T. Herawan, "Predicting tuition fee payment problem using backpropagation neural network model," *International Journal of Advanced Science and Technology*, vol. 120, pp. 85–96, 2018, doi: 10.14257/ijast.2018.120.07.

[16] Sumijan, A. P. Windarto, A. Muhammad, and Budiharjo, "Implementation of neural networks in predicting the understanding level of students subject," *International Journal of Software Engineering and its Applications*, vol. 10, no. 10, pp. 189–204, 2016, doi: 10.14257/ijseia.2016.10.10.18.

[17] S. Sunardi, A. Yudhana, and G. Z. Muflih, "Sistem Prediksi Curah Hujan Bulanan Menggunakan Jaringan Saraf Tiruan Backpropagation," *Jurnal Sistem Informasi Bisnis*, vol. 10, no. 2, pp. 155–162, 2020, [Online]. Available: <http://ejournal.undip.ac.id/index.php/jsinbis>.

[18] P. Li and Q. Zhang, "Face Recognition Algorithm Comparison based on Backpropagation Neural Network," *Journal of Physics: Conference Series*, vol. 1865, no. 4, 2021, doi: 10.1088/1742-6596/1865/4/042058.

[19] R. Ruslan, L. Laome, I. Usman, and E. W. Harisa, "Electricity Consumption Modelling in Kendari using the Backpropagation Method on the Artificial Neural Network," *Journal of Physics: Conference Series*, vol. 1863, no. 1, 2021, doi: 10.1088/1742-6596/1863/1/012076.

[20] S. Nurhasanah, I. Ranggadara, I. Prihandi, and A. Ratnasari, "Backpropagation neural network for predict sugarcane stock availability," *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 9, no. 5, pp. 8279–8284, 2020, doi: 10.30534/ijatcse/2020/197952020.