



Analisa Dini Gangguan Disleksia Anak Sekolah dengan Metode *Backpropagation*

Novi Yanti^{#1}, Adil Setiawan^{*2}, Sarjond Defit⁺³

[#]Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Riau
Jl. HR. Soebrantas No.Km. 15, RW.15, Simpang Baru, Kota Pekanbaru, Riau

¹novi_yanti@uin-suska.ac.id

^{*}Rekayasa Perangkat Lunak, Universitas Potensi Utama, Tanjung Mulia, Medan
Jl. KL. Yos Sudarso Km. 6,5 No. 3-A, Tanjung Mulia, Tj. Mulia, Kec. Medan Deli, Kota Medan, Sumatera Utara

²adiol65@gmail.com

⁺Teknologi Informasi, Universitas Putra Indonesia YPTK Padang, Padang
Jl. Raya Lubuk Begalung, Lubuk Begalung Nan XX, Kec. Lubuk Begalung, Kota Padang, Sumatera Barat

³sarjond@yahoo.co.uk

Abstrak— Disleksia sering disalah artikan sebagai kebodohan atau kemalasan pada anak. Gejala disleksia dikenal dengan gangguan belajar yang meliputi mengenal huruf, mengeja, membaca, dan menulis. Meskipun gejala disleksia tidak terlihat dengan jelas, kondisi ini dapat berdampak pada perkembangan pola belajar anak. Tujuan penelitian adalah untuk mengidentifikasi gejala disleksia sedini mungkin agar tidak mengganggu perkembangan belajar pada anak. Selain itu, penelitian juga bertujuan untuk mengevaluasi keakuratan teknik yang digunakan. Analisa menggunakan metode jaringan syaraf tiruan dengan teknik *backpropagation* dengan memberikan nilai bobot, sehingga dapat memberikan nilai input dengan benar. Penelitian menggunakan 150 dataset, 40 variabel input dan 40 lapisan tersembunyi. Keluaran yang diharapkan mencakup disleksia atau non-disleksia. Hasil implementasi dan pengujian untuk data latih dan data uji terbaik adalah 90:10. Dengan nilai epoch maksimum 5000 dan nilai error target 0,001. Metode *backpropagation* dapat memberikan hasil akurasi terbaik 100% pada learning rate 0,5. Sehingga metode *backpropagation* dapat dengan baik mendeteksi gangguan disleksia pada anak sejak dini.

Kata kunci: *Backpropagation*, Disleksia Anak, Gangguan Belajar.

I. PENDAHULUAN

Learning Disabilities (LD) merupakan gangguan belajar yang dialami 5-10% anak di dunia. Ciri umum anak LD memiliki perbedaan signifikan pada prestasi belajar akademik dan kemampuan belajar anak-anak. Anak-anak penderita LD memiliki IQ di atas nilai rata-rata. LD tidak memiliki kaitan dengan tingkat IQ [1], [2]. Anak LD dengan anak normal lainnya dibedakan berdasarkan kemampuan otak untuk menangkap dan mengolah informasi. Dasar penderita LD tidak dapat dilihat, dan diperkirakan adanya hubungan pada factor genetika (gen), interaksi lingkungan (logam berat), atau gangguan pada

saat kehamilan (penggunaan obat-obatan, alkohol, atau terinfeksi) [3].

LD mulai diketahui saat anak mencapai usia sekolah, diagnosis jika anak memiliki ketidakmampuan belajar setidaknya dimasa 6 bulan dan tidak terdapat gangguan yang lain misalkan adanya gangguan bicara, gangguan pendengaran, atau gangguan pemikiran [1], [4]. Salah satu gangguan LD adalah disleksia yang merupakan ketidakmampuan belajar anak yang ditandai dengan kesulitan pengenalan kata, ejaan, decoding dan pemahaman bacaan pada anak yang memiliki motivasi, kecerdasan, dan pendidikan yang diperlukan. Ciri-ciri penting lainnya adalah berjuang untuk membaca, menulis, dan berbicara bersama dengan kesulitan dalam manipulasi suara dan ejaan, penurunan kinerja dalam memori fonologis dan kosa kata [2], [5], [6].

Bagaimana cara mengidentifikasi ketidakmampuan belajar anak sejak dini? Tidak ada cara praktis untuk mengatasi disleksia, terutama disleksia yang berasal dari kelainan genetika turunan dari keluarga. Disleksia tidak dapat terlihat pada saat anak-anak kemudian berlanjut hingga dewasa. Jika kemampuan anak dalam membaca sangat rendah dari anak yang lain atau memiliki tanda atau memperlihatkan gejala seperti yang telah dijelaskan, diagnosis dini terhadap masalah ini harus segera dilakukan. Ketidakmampuan belajar anak dapat menghambat perkembangan mereka di sekolah [5]. Kurangnya kesadaran orang tua di kalangan disleksia adalah kelemahan utama dalam kehidupan anak-anak menuju kesuksesan mereka [4].

Artificial Intelligence (AI) merupakan ilmu komputer yang dapat digunakan sebagai pemecahan masalah terkait identifikasi. Jaringan Syaraf Tiruan (JST) sebagai bagian dari AI dapat didefinisikan sebagai kumpulan model simulasi syaraf biologis. Model saraf dibuktikan melalui

proses emulasi dan analisis, diikuti dengan prediksi dan asosiasi [7].

Backpropagation merupakan salah satu metode identifikasi dalam JST. Penerapan dan implementasi *backpropagation* termasuk dalam teknik algoritma pelatihan yang menerapkan teknik pembelajaran koreksi kesalahan [8]. *Backpropagation* adalah algoritma pembelajaran supervised (terawasi) [9] yang menggunakan teknik perceptron dengan multileyer untuk mengubah bobot lapisan [1] dengan pola pembobotan untuk mencapai nilai kesalahan minimum antara output yang diprediksi dan aktual [10], [11], [12], [13].

Karakteristik utama *backpropagation* dapat melatih jaringan kecerdasan buatan untuk penurunan gradien. Ini dianggap sebagai aktivitas jaringan saraf [14]. Metode yang berulang dan efektif digunakan untuk menghitung nilai bobot dalam meningkatkan jaringan sehingga dapat melakukan perhitungan [15]. Selama pembentukan jaringan, dapat diketahui beberapa fungsi aktivasi yang diperlukan [16].

Algoritma *backpropagation* mempropagasi kesalahan melalui jaringan saraf dan pembaruan bobot terjadi [17], memiliki fungsi latihan dan fungsi transfer. Fungsi-fungsi ini memiliki banyak teknik serta jalur memecahkan masalah kompleks [18]. Fungsi transfer banyak digunakan dalam jaringan syaraf untuk pembelajaran mesin, terutama dalam algoritma *backpropagation* seperti fungsi hiperbolik Tangens (Tangen Sigmoid) [19], logsig (log-sigmoid) [20] dan linear-purelin [21]. Kemudian memiliki traingd, traingdx, traingda, dan traingdm sebagai fungsi pelatihan *gradient descent* [22].

Beberapa fungsi pelatihan dapat mempengaruhi keluaran hasil optimasi misalnya *trainscg* (gradien konjugasi berskala), pelatihan *trainr* (urutan acak), *trainbr* (regulasi bayesian) [23], pelatihan *trainru* (bobot/bias tidak terawasi), *trainlm* (Levenberg-Marguardt) [24], [25], *trainoss* (OSS) [26], pelatihan *trains* (incremental fungsi pembelajaran) [27], pelatihan *trainbu* (bobot tanpa pengawasan) [28], pelatihan *trainb* (aturan pembelajaran bobot) [29], *traingcgp*, *traingcgb*, *traingcf* (pelatihan konjugasi gradien) [30], *trainrp* (resilient) [31], BFGS *trainbfg* (quasi-newton) [32], *traingc* (urutan nilai bobot/bias) serta BFGS *trainbfgc* (referensi quasi-newton) [33].

Menggunakan fungsi pelatihan dan fungsi transfer untuk memberikan hasil prediksi dengan akurasi bervariasi, didasari oleh nilai parameter atau teknik yang digunakan dan data yang diuji [34], [35], [36], [37], [38]. Oleh sebab itu, penelitian ini menggunakan algoritma *backpropagation* dalam melakukan fungsi pelatihan.

Diagnosa dan identifikasi gangguan *Specific Learning Disabilities* (SLD) menggunakan alat skala pengujian dalam bentuk tes melalui kuis. Beberapa pertanyaan tes khusus diulang tiga kali sesuai jenis gangguan belajar yang dialami. Setelah pengujian selesai, data yang dihasilkan diberikan sebagai input ke algoritma *decision tree*. Berdasarkan nilai siswa dan waktu yang diambil, algoritma *decision tree* memprediksi ketidakmampuan belajar anak-anak. Alat yang diusulkan dikembangkan secara

terintegrasi dan mudah digunakan sehingga sangat akurat dalam mengidentifikasi gangguan membaca, menulis dan matematika. Menyarankan cara belajar yang benar dan paling tepat kepada orang tua dan guru [6].

Persoalan diagnosis disleksia pernah dilakukan dengan menerapkan *One Dimensional Convolutional Neural Network* (1D CNN) berdasarkan sinyal *Electrooculogram* (EOG). Sinyal EOG melakukan klasifikasi menggunakan CNN 1D dengan hasil perolehan akurasi 73,6128 kelompok sehat dan 2,8155% merupakan kelompok menderita disleksia [6].

Pada penelitian berikutnya hasil pengklasifikasi dapat membedakan antara tiga kelas yaitu disleksia, sehat dan gangguan. Berdasarkan klasifikasi item data (objek) dari dataset yang diusulkan, dampak tinggi antara lain: (1) serangan kata dan strategi membaca, (2) pemrosesan auditori, dan (3) pemrosesan visual. Akurasi rata-rata 96% dalam tiga pengklasifikasi. Sistem yang diusulkan sangat akurat dibandingkan dengan diagnose secara tradisional. Teknologi *Augmented Reality* (AR) [3] untuk alat pengajaran dengan cepat menjadi populer karena perpaduan unik antara dunia nyata dan virtual. Penggunaan AR untuk mengajar anak-anak khusus yang menderita disleksia, akan menjadi cara yang bagus untuk mengajar dan melatih. Teknologi AR digunakan untuk mengembangkan aplikasi yang komprehensif secara khusus didasarkan pada aturan pedagogis seperti yang diusulkan oleh *International Dyslexic Organization* (IDO). Sistem membuat satu set pelajaran unik dalam bentuk buklet, yang memungkinkan anak untuk menggunakan dan belajar dalam kombinasi dengan AR berisi objek 2D dan 3D [4].

Berdasarkan penelitian sebelumnya, maka penelitian ini melakukan analisa awal gangguan disleksia anak menggunakan metode *backpropagation*. Tujuannya untuk mengubah nilai bobot sehingga melatih jaringan saraf memetakan input ke output dengan benar. Teknik dan metode fungsi pelatihan diharapkan dapat menyelesaikan persoalan gangguan disleksia. Dataset inputan dipakai untuk proses data latih dan data uji. Diharapkan hasil penelitian dapat melakukan deteksi dini anak penderita SLD sehingga dapat memudahkan guru dan psikolog dalam mengenali gangguan disleksia pada anak.

II. METODE

A. Dataset

Data untuk penelitian ini terdiri dari 150 data pasien yang menderita LD. Data primer yang digunakan berasal dari pengisian kuisioner yang dilakukan oleh Wali Kelas 1 sampai dengan kelas 5 pada 5 Sekolah Dasar (SD) yang ada di kota Pekanbaru. Data yang digunakan berada pada rentang usia antara 6 sampai 11 tahun. Dataset dapat dilihat pada TABEL I.

Selanjutnya, proses normalisasi data, membangun arsitektur jaringan backpropagation, dan implementasikan pelatihan dan pengujian dengan dataset menggunakan Matlab R2021a.

III. ANALISA

Data input terdiri dari X_1, X_2, \dots, X_{40} , sedangkan Kelas sebagai keluaran dapat dilihat pada TABEL III.

TABEL III
KELAS (OUTPUT)

Kelas	Keterangan	Output (Y_0)
1	Disleksia	1
2	Non-Disleksia	0

Langkah transformasi data dengan variabel input X_2 adalah untuk jenis kelamin dan variabel input X_3 - X_{40} adalah untuk penentuan nilai Yes atau No (Y/N). Nilai transformasi data berada pada skala 0 atau 1, seperti yang disajikan pada TABEL IV.

TABEL IV
TRANSFORMASI DATA

Variabel	Keterangan	Transformation Data
X_2	Laki-laki	1
	Perempuan	0
X_3, \dots, X_{40}	Y	1
	N	0

A. Normalisasi Data

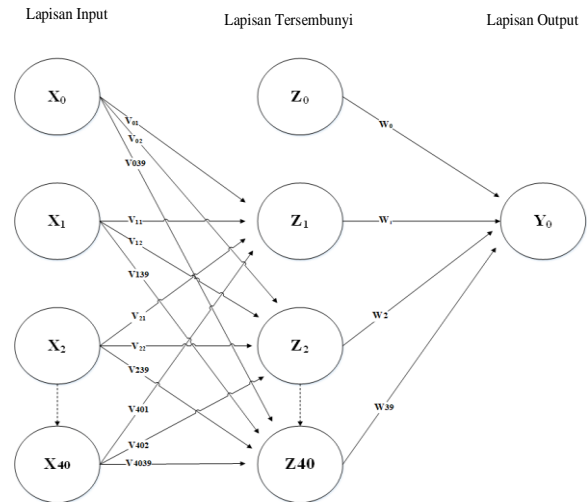
TABEL V berikut menunjukkan hasil normalisasi data untuk 150 dataset yang memiliki 40 variabel inputan yang digunakan.

TABEL V
NORMALISASI DATA

No	Variable								
	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_{40}	Kelas
1			0	0	0	0	...	00	00
2	1	1	0	0	0	0	...	00	00
3	0.750	0	0	0	0	0	...	00	00
4	0.250	0	0	0	0	0	...	00	00
5	0.750	1	0	0	0	0	...	00	00
6	00	0	0	0	0	0	...	00	00
7	0.50	1	1	1	1	1	...	1	1
8	0.50	1	1	1	1	1	...	1	1
9	1	1	0	0	0	0	...	00	00
10	0.50	1	1	1	1	1	...	1	1
...
15	00	1	1	1	1	1	...	1	1

B. Analisa Backpropagation

Analisa metode *backpropagation* dimulai dengan membangun arsitektur jaringan. Kemudian dilanjutkan dengan tahap pelatihan dan pengujian. Gambar 2 berikut merupakan tampilan rancangan arsitektur *backpropagation*.



Gambar 2 Rancangan arsitektur *backpropagation*

Tampilan pada Gambar. 2 menjelaskan bahwa:

- 40 variabel input yaitu $X_1 - X_{40}$
- 40 lapisan tersembunyi yaitu $Z_1 - Z_{40}$
- 1 lapisan output yaitu Y_0
- Bobot X_1 - X_{40} dihubungkan dengan lapisan tersembunyi V_1, V_2, \dots, V_{40}
- Bobot V_{ij} menghubungkan jaringan neuron input ke- i ke- j pada lapisan tersembunyi
- V_1, V_2, \dots, V_{40} adalah bobot bias
- Z_1, Z_2, \dots, Z_{40} bobot lapisan tersembunyi ke lapisan keluaran Y_0 adalah W_{j0}
- Fungsi aktivasi menggunakan sigmoid biner.

Selanjutnya adalah tahapan pelatihan dan pengujian data. Tahap pelatihan fase I menggunakan propagasi feedforward. Fase II merupakan tahapan propagasi balik, dan fase III tahapan fase perubahan nilai bobot untuk tahap pengujian menggunakan tahap propagasi lanjutan.

C. Tahap Pelatihan

Pemberian nilai bobot awal dan nilai bobot bias awal melalui rentang nilai 0 hingga 1. Lapisan input diberi nilai bobot awal untuk ke lapisan tersembunyi hasil seperti pada TABEL VI.

TABEL VI
NILAI BOBOT AWAL LAPISAN INPUT KE LAPISAN TERSEMBUNYI

V_1	V_2	V_3	V_4	V_5	V_6	V_7	V_8	$V_{..}$	V_{40}
0.1	0.3	0.2	0.4	0.2	0.5	0.3	0.1	...	0.09

Bobot nilai awal lapisan tersembunyi hingga lapisan output seperti pada TABEL VII.

TABEL VII

INISIALISASI WEIGHT DARI LAPISAN HIDDEN KE LAPISAN OUTPUT

W ₁	W ₂	W ₃	W ₄	W ₅	W ₆	W ₇	W ₈	W _{..}	W ₄₀
0.2	0.3	0.4	0.1	0.5	0.6	0.1	0.2	...	0.2

Tahapan pelatihan diinisialisasi nilai maximum *epoch* = 1000, $\alpha = 0.1$, target *error* 0.001. Hasil fase I untuk propagasi feedforward seperti terlihat pada TABEL VIII dan TABEL IX.

TABEL VIII
NILAI OPERASI LAPISAN TERSEMBUNYI

Z _{net1}	Z _{net2}	Z _{net3}	Z _{net4}	Z _{net5}	...	Z _{net30}
8.285	8.735	8.275	8.8	9.015	...	8.5345

TABEL IX
FUNGSI AKTIVASI DI LAPISAN TERSEMBUNYI

Z ₁	Z ₂	Z ₃	Z ₄	Z ₅	...	Z ₄₀
0.9997	0.9998	0.9997	0.9998	0.9999	...	0.9998

Hasil proses fase II untuk backpropagation seperti pada tampilan TABEL X dan tampilan TABEL XI.

TABEL X
KORELASI NILAI BOBOT T₀

ΔW ₀₁	ΔW ₀₂	ΔW ₀₃	...	ΔW ₀₄₀
-0.00019994	-0.00019996	-0.00019994	...	-0.00019996

TABEL XI
KORELASI BIAS T₀

Δv ₁	Δv ₂	Δv ₃	...	Δv ₄₀
-0.00000387	-0.00000214	-0.00000265	...	-0.00000467

Fase III adalah fase perubahan nilai bobot V₁ sampai V₄₀ seperti pada tampilan TABEL XII, TABEL XIII dan TABEL XIV.

TABEL XII
NILAI BOBOT BARU DI LAPISAN TERSEMBUNYI

No	1	2	3	...	40
V ₁	0.09999 905	0.29999980	0.199999 98	...	0.08999904
V ₂	0.29999 905	0.29999980	0.699999 98	...	0.49999992
V ₃	0.09999 605	0.09999880	0.199991 98	...	0.29999998
V ₄	0.19999 605	0.29999880	0.299991 98	...	0.59999993
...
V ₄₀	0.08999 605	0.49999980	0.299991 98	...	0.34999995

TABEL XIII
NILAI BIAS BARU DI LAPISAN TERSEMBUNYI

V ₀₁ (new)	V ₀₂ (new)	V ₀₃ (new)	...	V ₀₄₀ (new)
0.49999613	0.19999786	0.29999735	...	0.0999533

Nilai bobot baru untuk lapisan hidden hingga lapisan keluaran dari W₁-W₄₀ dapat dilihat pada TABEL XIV.

TABEL XIV
BOBOT PADA LAPISAN TERSEMBUNYI KE LAPISAN KELUARAN

	W ₁ (new)	W ₂ (new)	W ₃ (new)	...	W ₄₀ (new)
Y ₀	0.19980006	0.299990131	0.399989924	...	0.199990082

D. Tahap Pengujian

Hasil operasi pada lapisan tersembunyi Z_{net₁} hingga Z_{net₄₀} terlihat pada tabel XV.

TABEL XV
OPERASI PADA LAPISAN TERSEMBUNYI

Z _{net1}	Z _{net2}	Z _{net3}	...	Z _{net40}
12.521281	14.341390	13.758485	...	18.374890

Nilai aktivasi lapisan tersembunyi memperoleh nilai Z_{net₁} = 12.5212819.

$$Z_1 = \frac{1}{1+e^{-Z_{net1}}} = \frac{1}{1+e^{-12.5212819}} = 0.0000036$$

Hasil fungsi aktivasi pada lapisan tersembunyi Z₁ hingga Z₄₀ terlihat pada tabel XVI.

TABEL XVI
FUNGSI AKTIVASI DI LAPISAN TERSEMBUNYI

Z ₁	Z ₂	Z ₃	...	Z ₄₀
0.000003	0.00007	0.000004	...	0.000008

Hasil Z₁-Z₄₀ didapatkan dari bobot awal lapisan tersembunyi ke lapisan output (W₁-W₄₀), dan bobot awal bias ke lapisan output didapatkan W₀=0,49999.

Fungsi aktivasi pada lapisan keluaran Y_{net₀} adalah sebagai berikut:

$$Y_{net_0} = 74.4984$$

Sehingga, keluaran yang dihasilkan adalah sebagai berikut:

$$Y_k = \frac{1}{1+e^{-Y_{netk}}}$$

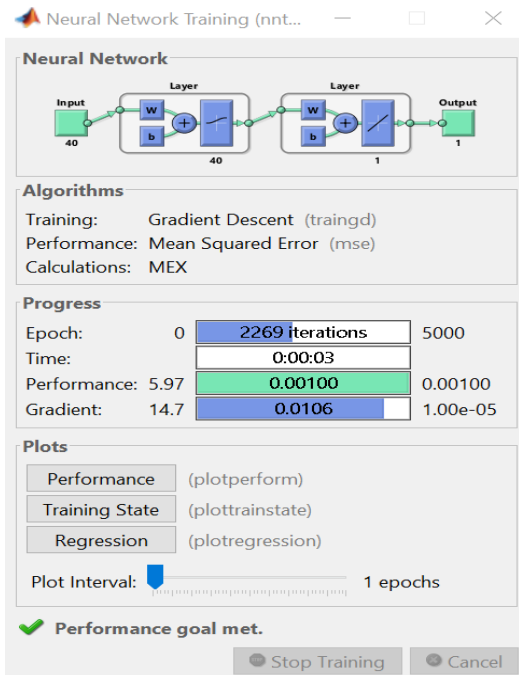
$$Y_0 = \frac{1}{1+e^{-74.4984}} = 0.000000000000442 =$$

0

Jika; $Y_k \geq 0.5$, maka nilai $Y_k = 1$
Jika $Y_k < 0.5$, maka nilai $Y_k = 0$

Hasil analisis dapat disimpulkan bahwa nilai keluaran (Y₀) adalah 0, masuk ke dalam keluaran: **Kelas 1** yaitu **Non-Disleksia**.

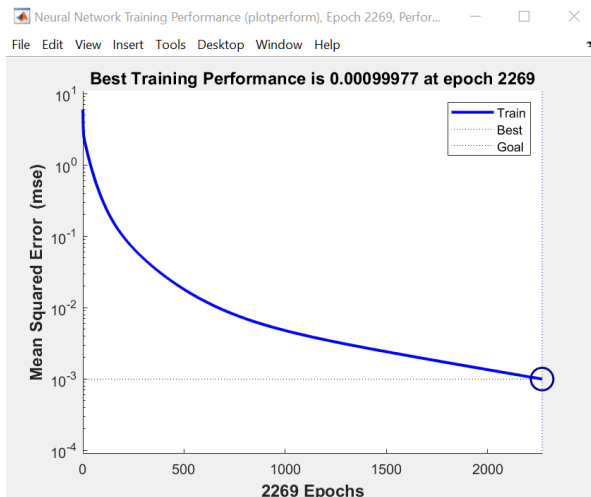
Selanjutnya, proses pelatihan *backpropagation* menggunakan tools Matlab R2020a yang seperti yang ditunjukkan pada Gambar 3.



Gambar 3 Pelatihan *backpropagation*

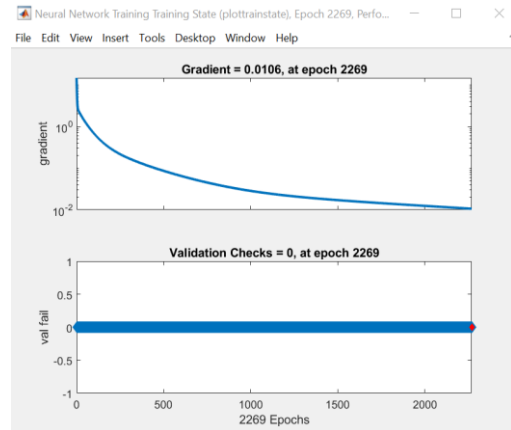
Pada Gambar 3 terlihat 40 nilai variabel input, 40 lapisan tersembunyi, satu lapisan keluaran, menggunakan sepuluh data latih dan 10 data uji, menggunakan 5000 epoch dalam 3 detik, performansi 0,001, dan gradien 0,01.

Grafik performa yang dihasilkan pada nilai epoch 2269 memberikan nilai Mean Squared Error (MSE) terbaik di 0.00099977 seperti yang ditunjukkan pada tampilan Gambar 4.



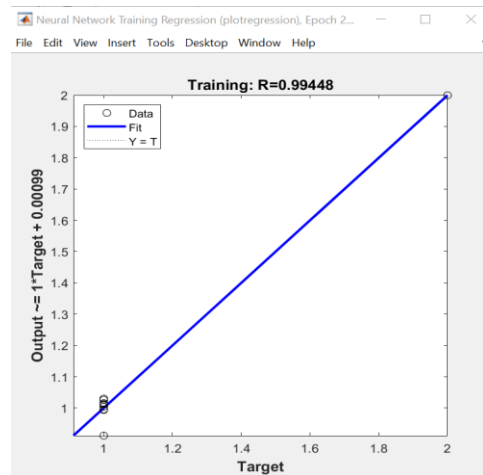
Gambar 4 The resulting performance

Nilai epoch 2269 memberikan nilai gradien di 0.0106 dan nilai validasi pelatihan 0 grafik status pelatihan seperti ditunjukkan pada Gambar 5.



Gambar 5 Training state

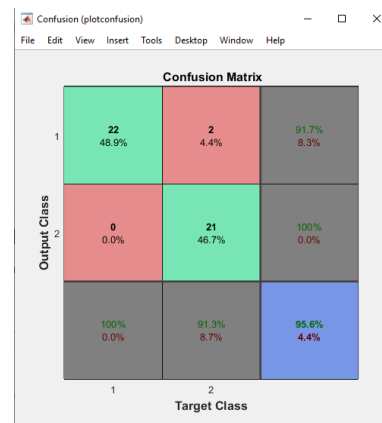
Sedangkan nilai dari pelatihan regresi $R=0.99448$ dengan nilai keluaran 0.00099, seperti ditunjukkan Gambar 6.



Gambar 6 Training regression

E. Hasil Pengujian

Tahapan pengujian dilakukan dengan membagi data menjadi data latih dan data uji. Kemudian menentukan nilai akurasi dari setiap pengujian yang dilakukan. Pengujian nilai akurasi menggunakan confusion matrix, seperti yang terlihat pada Gambar 7.



Gambar 7 Confusion matrix

Pengujian dilakukan dengan perbandingan data latih dan data uji dari 150 dataset yang digunakan. Akan dilakukan pengujian nilai parameter untuk mendapatkan nilai akurasi.

TABEL XVII berikut adalah pembagian jumlah data latih dan data uji.

TABEL XVII
PENGUJIAN DATA LATIH DAN DATA UJI

No	Pengujian Data	Data Latih	Data Uji
1	90:10	135	15
2	80:20	120	30
3	70:30	105	45

Hasil pengujian dengan menggunakan learning rate 0.01, 0.1, 0.2, dan 0.5, menggunakan lapisan tersembunyi 40 dengan perbandingan data 90:10, 80:20, 70:30 dan nilai akurasi yang dihasilkan dapat dilihat pada TABEL XVIII berikut ini.

TABEL XVIII
PENGUJIAN DATA DAN NILAI AKURASI DENGAN LAPISAN TERSEMBUNYI 40

No	α	Pengujian Data	Data Latih	Data Uji	Nilai Akurasi
1	0.01	90:10	135	15	100%
2	0.01	80:20	120	30	93,3%
3	0.01	70:30	105	45	84,4%
4	0.1	90:10	135	15	93,3%
5	0.1	80:20	120	30	93,3%
6	0.1	70:30	105	45	93,3%
7	0.2	90:10	135	15	93,3%
8	0.2	80:20	120	30	93,3%
9	0.2	70:30	105	45	97,8%
10	0.5	90:10	135	15	100%
11	0.5	80:20	120	30	93,3%
12	0.5	70:30	105	45	88,9%

Hasil pengujian dengan menggunakan learning rate 0.01, 0.1, 0.2, dan 0.5, menggunakan lapisan tersembunyi 79 dengan perbandingan data 90:10, 80:20, 70:30 dan nilai akurasi yang dihasilkan dapat dilihat pada TABEL XIX berikut ini.

TABEL XIX
PENGUJIAN DATA DAN NILAI AKURASI DENGAN LAPISAN TERSEMBUNYI 79

No	α	Pengujian Data	Data Latih	Data Uji	Nilai Akurasi
1	0.01	90:10	135	15	80.0%
2	0.01	80:20	120	30	93.3%
3	0.01	70:30	105	45	88.9%
4	0.1	90:10	135	15	93.3%
5	0.1	80:20	120	30	96.7%
6	0.1	70:30	105	45	100%
7	0.2	90:10	135	15	93.3%
8	0.2	80:20	120	30	86.7%
9	0.2	70:30	105	45	95.6%
10	0.5	90:10	135	15	100%
11	0.5	80:20	120	30	90.0%
12	0.5	70:30	105	45	93.3%

Dari hasil pengujian dengan menggunakan learning rate 0.01, 0.1, 0.2, dan 0.5, menggunakan lapisan tersembunyi 40 dan 79 dengan perbandingan data 90:10, 80:20, 70:30

dan nilai akurasi yang dihasilkan dapat dilihat pada TABEL XX berikut ini.

TABEL XX
KESIMPULAN PENGUJIAN DATA DENGAN NILAI AKURASI DENGAN LAPISAN TERSEMBUNYI 40 DAN 79

No	α	Lapisan Tersembunyi	Nilai Akurasi		
			70:30	80:20	90:10
1	0.01	40	84.4%	93.3%	100%
2	0.1	40	93.3%	93.3%	93.3%
3	0.2	40	97.8%	93.3%	93.3%
4	0.5	40	88.9%	93.3%	100%
5	0.01	79	88.9%	93.3%	80.0%
6	0.1	79	100%	96.7%	93.3%
7	0.2	79	95.6%	86.7%	93.3%
8	0.5	79	93.3%	90.0%	100%

Dari hasil pengujian yang telah dilakukan, dapat disimpulkan bahwa nilai akurasi tertinggi berada pada nilai learning rate 0.5 dan 0.01 di lapisan tersembunyi 40 dan 0.5 dilapisan tersembunyi 79, dengan nilai akurasi 100%. Sedangkan untuk perbandingan data latih dan data uji adalah terbaik adalah pada 90:10 dengan jumlah data 135:15 dari 150 dataset yang digunakan.

IV. KESIMPULAN

Jurnal ini melakukan analisa dini terhadap gangguan disleksia pada anak sekolah dengan menerapkan metode *backpropagation*. Hasil implementasi menunjukkan bahwa metode *backpropagation* dapat digunakan untuk analisis awal gangguan disleksia pada anak sesuai dengan tujuan penelitian. Pengujian parameter dengan nilai *learning rate* (α) 0.5 dan 0.01, epoch maksimum 5000 dengan target error 0,001 pada lapisan tersembunyi 40 dan 79, dan lapisan keluaran 1. Hasil pengujian data menunjukkan bahwa nilai akurasi mencapai 100%. Nilai *learning rate* (α) juga dipengaruhi oleh perbandingan jumlah data uji dan data latih yang digunakan.

REFERENSI

- [1] J. Amrutha and A. S. Remya Ajai, "Performance analysis of backpropagation algorithm of artificial neural networks in verilog," *2018 3rd IEEE Int. Conf. Recent Trends Electron. Inf. Commun. Technol. RTEICT 2018 - Proc.*, pp. 1547–1550, 2018.
- [2] R. Ileri, F. Latifoglu, and E. Demirci, "New Method to Diagnosis of Dyslexia Using 1D-CNN," *TIPTEKNO 2020 - Tip Teknol. Kongresi - 2020 Med. Technol. Congr. TIPTEKNO 2020*, pp. 5–8, 2020.
- [3] Z. Bhatti, M. Bibi, and N. Shabbir, "Augmented Reality based Multimedia Learning for Dyslexic Children," *2020 3rd Int. Conf. Comput. Math. Eng. Technol. Idea to Innov. Build. Knowl. Econ. iCoMET 2020*, 2020.
- [4] J. Jincy and P. S. H. Jose, "Survey on intervention & diagnosis of dyslexia," *Proc. 2021 1st Int. Conf. Adv. Electr. Comput. Commun. Sustain. Technol. ICAECT 2021*, no. February, pp. 1–5, 2021.
- [5] J. Dhas and S. Hency Jose, "A Study on Dyslexia Using Machine Learning-Review," *EasyChair Prepr.*, 2021.
- [6] H. M. Al-Barhamtoshy and D. M. Motaweh, "Diagnosis of Dyslexia using computation analysis," *2017 Int. Conf. Informatics, Heal. Technol. ICIHT 2017*, no. 1, 2017.
- [7] A. Frid and L. M. Manevitz, "Design and Selection of Features under ERP for Correlating and Classifying between Brain Areas

- and Dyslexia via Machine Learning,” *Proc. Int. Jt. Conf. Neural Networks*, 2020.
- [8] Meizir and B. Rikumahu, “Prediction of agriculture and mining stock value listed in Kompas100 index using artificial neural network backpropagation,” *2019 7th Int. Conf. Inf. Commun. Technol. ICoICT 2019*, pp. 1–5, 2019.
- [9] J. Kaushal, “Plant Disease Detection Paper,” *SSRN Electron. J.*, vol. 10, no. 1, 2022.
- [10] M. Andrijasa *et al.*, “Penerapan Jaringan Syaraf Tiruan Untuk Memprediksi Jumlah Pengangguran di Provinsi Kalimantan Timur Dengan Menggunakan Algoritma Pembelajaran Backpropagation,” *J. Inform. Mulawarman*, vol. 5, no. 1, 2010.
- [11] G. B. Atkar and J. Priyadarshini, *Enhancing Readability of Dyslexic Children by Machine Learning Techniques—A Survey*, vol. 556. Springer Singapore, 2019.
- [12] S. C. Dubey, K. S. Mundhe, and A. A. Kadam, “Credit Card Fraud Detection using Artificial Neural Network and BackPropagation,” *Proc. Int. Conf. Intell. Comput. Control Syst. ICICCS 2020*, no. Iccics, pp. 268–273, 2020.
- [13] P. W. Samodro, S. W. Sihwi, and Winarno, “Backpropagation implementation to classify dysgraphia in children,” *Proceeding - 2019 Int. Conf. Artif. Intell. Inf. Technol. ICAIIT 2019*, pp. 437–442, 2019.
- [14] R. Sovia, M. Yanto, and W. Nursanty, “Backpropagation Algorithm on Implementation of Signature Recognition,” *J. Comput. Scine Inf. Technol.*, vol. 7, no. 2, pp. 21–29, 2021.
- [15] V. Çetin, H. H. Yumrukaya, and Ç. Bakır, “Detection of Lung Cancer with Enhanced Feed Forward Backpropagation Artificial Neural Networks,” pp. 2163–2171, 2023.
- [16] P. Tembhurne, N. Deshpande, A. Moharil, N. Raut, S. Kamdi, and A. Yerlekar, “Learning disability analysis and prediction,” no. 05, pp. 3252–3256, 2022.
- [17] S. Karn, S. Sangole, A. Gawde, and J. Joshi, “Prediction and classification of vector-borne and communicable diseases through artificial neural networks,” *2019 Int. Conf. Intell. Comput. Control Syst. ICCS 2019*, no. Iccics, pp. 1011–1015, 2019.
- [18] S. Tang and Y. Yang, “Why neural networks apply to scientific computing?,” *Theor. Appl. Mech. Lett.*, vol. 11, no. 3, p. 100242, 2021.
- [19] I. C. Afolabi, S. I. Popoola, and O. S. Bello, “Modeling pseudo-second-order kinetics of orange peel-paracetamol adsorption process using artificial neural network,” *Chemom. Intell. Lab. Syst.*, vol. 203, p. 104053, 2020.
- [20] A. Alalousi, R. Razif, M. AbuAlhaj, M. Anbar, and S. Nizam, “A Preliminary Performance Evaluation of K-means, KNN and EM Unsupervised Machine Learning Methods for Network Flow Classification,” *Int. J. Electr. Comput. Eng.*, vol. 6, no. 2, p. 778, 2016.
- [21] A. Panyafong, N. Neamsorn, and C. Chaichana, “Heat load estimation using Artificial Neural Network,” *Energy Reports*, vol. 6, pp. 742–747, 2020.
- [22] E. W. Prasetyo, N. Hidetaka, D. A. Prasetya, W. Dirgantara, and H. F. Windi, “Spatial Based Deep Learning Autonomous Wheel Robot Using CNN,” *Lontar Komput. J. Ilm. Teknol. Inf.*, vol. 11, no. 3, p. 167, 2020.
- [23] M. Zandieh, A. Azadeh, B. Hadadi, and M. Saberi, “Application of artificial neural networks for airline number of passenger estimation in time series state,” *Journal of Applied Sciences*, vol. 9, no. 6, pp. 1001–1013, 2009.
- [24] I. B. K. Sudiarmika, F. Rahman, Trisno, and Suyoto, “Image forgery detection using error level analysis and deep learning,” *Telkonnika (Telecommunication Comput. Electron. Control.*, vol. 17, no. 2, pp. 653–659, 2019.
- [25] M. Žic, V. Subotić, S. Pereverzyev, and I. Fajfar, “Solving CNLS problems using Levenberg-Marquardt algorithm: A new fitting strategy combining limits and a symbolic Jacobian matrix,” *J. Electroanal. Chem.*, vol. 866, 2020.
- [26] J. Bilski, B. Kowalczyk, A. Marchlewska, and J. M. Zurada, “Local Levenberg-Marquardt Algorithm for Learning Feedforward Neural Networks,” *J. Artif. Intell. Soft Comput. Res.*, vol. 10, no. 4, pp. 299–316, 2020.
- [27] Q. H. Nguyen *et al.*, “A novel hybrid model based on a feedforward neural network and one step secant algorithm for prediction of load-bearing capacity of rectangular concrete-filled steel tube columns,” *Molecules*, vol. 25, no. 15, 2020.
- [28] P. Parulian *et al.*, “Analysis of Sequential Order Incremental Methods in Predicting the Number of Victims Affected by Disasters,” *J. Phys. Conf. Ser.*, vol. 1255, no. 1, 2019.
- [29] M. Attamimi, R. Mardiyanto, and A. N. Irfansyah, “Inclined image recognition for aerial mapping using deep learning and tree based models,” *Telkonnika (Telecommunication Comput. Electron. Control.*, vol. 16, no. 6, pp. 3034–3044, 2018.
- [30] N. L. W. S. R. Ginantra, M. A. Hanafiah, A. Wanto, R. Winanjaya, and H. Okprana, “Utilization of the Batch Training Method for Predicting Natural Disasters and Their Impacts,” *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1071, no. 1, p. 012022, 2021.
- [31] N. Shah and S. Jain, “Detection of Disease in Cotton Leaf using Artificial Neural Network,” *Proc. - 2019 Amity Int. Conf. Artif. Intell. AICAI 2019*, pp. 473–476, 2019.
- [32] R. Jayaseelan, G. Pandulu, and G. Ashwini, “Neural networks for the prediction of fresh properties and compressive strength of flowable concrete,” *J. Urban Environ. Eng.*, vol. 13, no. 1, pp. 183–197, 2019.
- [33] T. Afriliansyah and Z. Zufahmi, “Prediction of Life Expectancy in Aceh Province by District City Using the Cyclical Order Algorithm,” *Int. J. Inf. Syst. Technol. Akreditasi*, vol. 3, no. 36, pp. 268–275, 2020.
- [34] R. R. Pratama, “Analisis Model Machine Learning Terhadap Pengenalan Aktifitas Manusia,” *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 19, no. 2, pp. 302–311, 2020.
- [35] M. Tyrtaiou, A. Papaleonidas, A. Elenas, and L. Iliadis, *Accomplished Reliability Level for Seismic Structural Damage Prediction Using Artificial Neural Networks*. Springer International Publishing, 2020.
- [36] S. A. W. Fitra A. Bachtiar, Indra K. Syahputra, “Perbandingan Algoritme Machine Learning Untuk Memprediksi,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 5, pp. 543–548, 2019.
- [37] I. Ferima Talia, I. Fitri Astuti, and P. Studi Ilmu Komputer Fakultas Ilmu Komputer dan Teknologi Informasi, “Peramalan Tingkat Kemiskinan Penduduk Provinsi Kalimantan Timur Menggunakan Metode Double Exponential Smoothing Zainal Arifin,” *Pros. Semin. Nas. Ilmu Komput. dan Teknol. Inf.*, vol. 4, no. 2, pp. 121–127, 2019.
- [38] N. Choiriyati, Y. Arkeman, and W. A. Kusuma, “Deep learning model for metagenome fragment classification using spaced k-mers feature extraction,” *J. Teknol. dan Sist. Komput.*, vol. 8, no. 3, pp. 234–238, 2020.