

# Analisis Pengaruh Komposisi Data Training dan Testing Terhadap Akurasi Algoritma Resilient Backpropagation (RProp)

<sup>1</sup>Harly Okprana, <sup>2</sup>Riki Winanjaya  
<sup>1,2</sup>STIKOM Tunas Bangsa Pematangsiantar, Indonesia  
E-mail: <sup>1</sup>harly@amiktunasbangsa.ac.id

## Abstract

Prediction classification accuracy is a measure of success and satisfaction in predicting past data to produce accurate predictions, knowing how precise a classification pattern predicts class data from future data. In practice, artificial neural networks test the accuracy of a classification pattern using data testing, while to find the pattern itself, use training data. Errors in determining the composition of the presentation of training and testing data can affect the accuracy value obtained, therefore the distribution of the presentation of the amount of data from a dataset is one of the determining factors for the amount of accuracy. This study uses a dataset of Michigan Computer English Course students in 2018-2019 using the Resilient Backpropagation (RProp) method. The data processed was 100 student data for 2018-2019. By dividing the composition of 25% training data with 75% data testing with an accuracy value of 99.25% while dividing 50% training data with 50% data testing with an accuracy value of 100% as well as dividing 75% training data with 25% data testing with a value 100% accuracy.

**Keywords:** Resilient Backpropagation (RProp), TOEFL Prediction

## Abstrak

Akurasi klasifikasi prediksi merupakan tolak ukur keberhasilan dan kepuasan dalam memprediksi data masa lalu untuk menghasilkan prediksi yang akurat, mengetahui seberapa tepat suatu pola klasifikasi prediksi kelas data dari data yang akan datang. Dalam praktek jaringan saraf tiruan pengujian akurasi dari sebuah pola klasifikasi menggunakan data testing, sementara untuk menemukan pola itu sendiri, menggunakan data training. Kesalahan menentukan komposisi presentasi data training dan testing dapat mempengaruhi nilai akurasi yang diperoleh, oleh karena itu pembagian presentasi jumlah data keduanya dari sebuah dataset menjadi salah satu faktor penentu besaran nilai akurasi. Penelitian ini menggunakan dataset peserta didik Michigan Computer English Course tahun 2018-2019 menggunakan metode Resilient Backpropagation (RProp). Data yang diolah sebanyak 100 data peserta didik tahun 2018-2019. Dengan pembagian komposisi 25% data training dengan 75% data testing dengan nilai akurasi 99,25% sedangkan pembagian 50% data training dengan 50% data testing dengan nilai akurasi 100% begitu juga dengan pembagian 75% data training dengan 25% data testing dengan nilai akurasi 100%.

**Kata Kunci:** Resilient Backpropagation (RProp), Prediksi TOEFL

## 1. Pendahuluan

Ilmu komputer dahulu hanya sebuah mesin (komputer) yang membantu manusia dalam meringankan pekerjaan sehari-hari untuk melakukan perhitungan aritmatika dasar, saat ini ilmu komputer sudah berkembang hingga dapat mengerjakan pekerjaan sebaik dan seperti manusia yang disebut sebagai kecerdasan buatan atau disebut juga Artificial intelligent (AI) [1]. Kecerdasan buatan yang sangat banyak di terapkan dalam kehidupan

sehari-hari adalah Jaringan Saraf Tiruan (JST) dengan menggunakan metode Resilient yang sering digunakan untuk memprediksi pada data times series (berkelanjutan)[2], metode Resilient dipilih karena memiliki keunggulan dalam mencapai titik konvergen training lebih cepat dibandingkan dengan backpropagation[1]. Beberapa penelitian pendahulu terkait dengan penerapan Jaringan Syaraf Tiruan Resilient Backpropagation adalah seperti yang dilakukan[2],[3],[4],[5],[6]. Penggunaan Jaringan Saraf Tiruan (JST) sangat baik dalam hal peramalan ditunjukkan dengan performa serta akurasi yang baik[7].

Test of English as a Foreign Language (TOEFL) merupakan tes yang paling banyak di gunakan diseluruh dunia untuk pengukur kemampuan Bahasa Inggris yaitu tes untuk menguji kemampuan berbahasa Inggris aksen Amerika Serikat yang biasanya digunakan untuk masuk ke universitas unggulan, melamar kerja, bahkan proses kenaikan pangkat. Penyelenggaraan tes TOEFL biasanya terdiri dari 4 bagian yaitu listening comprehension, grammar structure and written expression, reading comprehension, dan writing[8],[9]. Michigan Computer English Course (MCEC) merupakan tempat bimbingan bahasa ingris yang mengakomodasi kebutuhan belajar bahasa ingris dari Beginner, Intermediate, Advanced, conversation hingga TOEFL. MCEC setiap tahunnya minimal melakukan tes simulasi TOEFL untuk para peserta bimbingan, setelah melakukan tes simulasi TOEFL peserta bimbingan mengikuti ujian TOEFL di lembaga penyelenggara TOEFL yang bereputasi, namun masi ada saja peserta bimbingan MCEC yang masi belum lulus. Untuk mengatasi masalah diatas perlunya sebuah metode yang bisa memprediksi atas lulusnya siswa bimbingan dalam ujian TOEFL tersebut. metode yang cocok digunakan untuk prediksi/peramalan yaitu metode Backpropagationkemudian akan dioptimasi menggunakan metode Resilient Backpropagation(Rprop). Berdasarkan uraian diatas, penelitian ini akan menerapkan algoritma resilient backpropagation dalam memprediksi kelulusan TOEFL peserta didik Michigan Computer English Course Pematangsiantar. Dengan dilakukannya prediksi terhadap kelulusan peserta didik dalam ujian TOEFL dapat dilakukan upaya-upaya persiapan serta pembekalan pada peserta didik sehingga diharapkan dapat lulus dengan baik pada ujian TOEFL sebenarnya.

## 2. Metodologi Penelitian

Metode Penelitian yang digunakan adalah Jaringan Saraf Tiruan dengan metode Resilient. Metode ini mampu melakukan prediksi berdasarkan data yang telah lampau (times series)[2]. Yaitu menggunakan data nilai ujian simulasi TOEFL Michigan Computer English Course tahun 2018-2019, data tersebut akan di uji untuk mendapatkan prediksi yang akurat menggunakan algoritma *Resilient Backpropagation (RProp)* untuk menghasilkan rekomendasi keputusan untuk Michigan Computer English Course.

### 2.1. Kecerdasan Buatan

Kecerdasan buatan (AI) adalah kesanggupan suatu sistem dalam menganalisis data mentah yang akurat, mengolah data untuk mencapai tujuan tertentu. Merupakan bagian dari ilmu komputer yang mempelajari bagaimana membuat mesin (komputer) dapat melakukan pekerjaan seperti dan sebaik yang dilakukan oleh manusia bahkan bisa lebih baik daripada yang dilakukan manusia[10],[11]. Salah satu yang dipelajari pada kecerdasan buatan adalah Jaringan Saraf Tiruan (JST) dengan menggunakan metode *Resilient Backpropagation*. Jaringan syaraf tiruan adalah sistem informasi yang memiliki karakteristik yang mirip dengan jaringan syaraf biologi[12].

### 2.2. Resilient Backpropagation

Resilient Backpropagation merupakan perkembangan dari backpropagation[13]. Resilient yaitu algortima *neural network* yang bersifat *supervised* dan *adaptive learning*. Pada resilient backpropagation parameter sudah ditetapkan jadi tidak diperlukan penentuan *learning rate* lagi [14],[10]. Tahap pelatihan *feedforward* pada algoritma resilient backpropagation sama dengan pada algoritma backpropagation, yang

membedakan algoritma tersebut yaitu pada waktu melakukan *updateweight* dengan *learningrate* pada pelatihan *backward*[15]. Perhitungan *learningrate* akan dijabarkan pada langkah-langkah sebagai berikut :

- a) Perhitungan Nilai  $\Delta_i^{(t)}$   
 Untuk menentukan nilai  $\Delta_i^{(t)}$  ada beberapa aturan yang harus dipenuhi untuk mendapat nilai delta tersebut yaitu :

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ * \Delta_{ij}^{(t-1)} & , if \frac{\partial E^{(t-1)}}{\partial \omega_i} * \frac{\partial E^{(t)}}{\partial \omega_i} > 0 \\ \eta^- * \Delta_{ij}^{(t-1)} & , if \frac{\partial E^{(t-1)}}{\partial \omega_i} * \frac{\partial E^{(t)}}{\partial \omega_i} < 0 \end{cases} \quad (1)$$

$\Delta_{ij}^{(t)}$ , else

Untuk mendapatkan  $\Delta_i^{(t)}$  untuk pertama kali pembelajaran  $\Delta_i^{(t-1)} = \Delta_0$  . Nilai  $\Delta_0 = 0.1$  nilai pada delta 0 dapat saja ditetapkan lebih besar atau lebih kecil dari 0.1, karena nilai delta 0 tidak memiliki pengaruh besar terhadap laju proses pembelajarannya. Untuk pembelajaran berikutnya maka  $\Delta_i$  yang terdahulu akan dikalikan dengan *learningrate*. Pada perkalian  $\Delta_i^{(t-1)}$  dengan *learningrate* ada aturan yang harus dicapai yaitu error gradien pada hasil terdahulu  $\frac{\partial E^{(t-1)}}{\partial \omega_i}$  dikalikan dengan errorgradien  $\frac{\partial E^{(t)}}{\partial \omega_i}$ . Dari hasil perkalian error tersebut maka didapatkan hasil jika hasil lebih besar dari 0 maka  $\Delta_i^{(t-1)}$  dikalikan dengan  $\eta^+$ , dan jika hasil lebih kecil dari 0 maka  $\Delta_i^{(t-1)}$  dikalikan dengan  $\eta^-$ . Nilai  $\eta^+$  dan  $\eta^-$  merupakan *learningrate* yang membedakan adalah pada  $\eta^+$  memiliki nilai yang lebih besar daripada menetapkan nilai standar pada  $\eta^+ = 1.2$  sedangkan  $\eta^- = 0.5$  untuk algoritma resilient propagation[16].

- b) Menentukan Nilai  $\Delta w_i^{(t)}$   
 Jika  $\Delta_i^{(t)}$  sudah ditentukan maka akan dilanjutkan kedalam aturan untuk menentukan fungsi operator yang akan dipakai untuk melakukan *updateweight* dengan aturan sebagai berikut :

$$\Delta w_i^{(t)} = \begin{cases} -\Delta_i^{(t)} & , if \frac{\partial E^{(t-1)}}{\partial \omega_i} > 0 \\ +\Delta_i^{(t)} & , if \frac{\partial E^{(t-1)}}{\partial \omega_i} < 0 \end{cases} \quad (2)$$

$$w_i^{(t+1)} = w_i^{(t)} + \Delta w_i^{(t)}$$

Dengan menggunakan *error function* maka diketahui  $\Delta_i^{(t)}$  yang akan digunakan apakah akan dikurangi atau ditambah atau tidak terjadi perubahan bobot. Untuk menentukan fungsi operator yang dipakai pada  $\Delta_i^{(t)}$  maka dibandingkan nilai *error gradien* terhadap nol. Jika nilai *error gradien* lebih besar daripada nol maka  $\Delta w_i^{(t)}$  akan menerima nilai  $-\Delta_i^{(t)}$ , dan jika nilai *error gradien* lebih kecil daripada 0 maka  $\Delta w_i^{(t)}$  akan menerima  $+\Delta_i^{(t)}$ . Setelah mendapatkan nilai delta w maka dilanjutkan ke *updateweightnya* secara langsung.

Pada aturan pertama untuk penentuan *learningrate* memiliki masalah pada aturan kedua yaitu terjadi peningkatan pembelajaran yang melebihi batas minimum maka dilakukan pengurangan *weight* secara langsung dengan *weight* terdahulunya.

$$\Delta w_i^{(t)} = -\Delta w_i^{(t-1)} & , if \frac{\partial E^{(t-1)}}{\partial \omega_i} * \frac{\partial E^{(t)}}{\partial \omega_i} < 0 \quad (3)$$

Untuk menghindari terjadi keadaan tersebut untuk terjadi kedua kalinya maka pada  $\frac{\partial E^{(t)}}{\partial \omega_i} = 0$

### 3. Hasil dan Pembahasan

Penelitian ini terfokus pada hasil akurasi dan jumlah epoch yang dihasilkan pada proses training dan testing yang disimulasikan dan dianalisis menggunakan algoritma

*Resilient Backpropagation (RProp)* Untuk parameter pada jaringan backpropagation yang akan digunakan pada penelitian ini dijelaskan pada Tabel 1:

**Tabel 1. Parameter Resilient Backpropagation (RProp)**

Karakteristik	Spesifikasi
Fungsi Aktivasi	Sigmoid biner
Inisialisasi bobot	Random
Target Error	0.005
Maksimum Epoch	100000
Learning Rate	0.1

Arsitektur jaringan *Resilient Backpropagation (RProp)* yang digunakan yaitu sebanyak 3 arsitektur. Tiap-tiap arsitektur berbeda jumlah *hidden layer*-nya, begitu juga dengan jumlah neuron setiap layer tersembunyi juga berbeda-beda. Untuk semua arsitektur jumlah neuron input pada *Input Layer* adalah 3 dan jumlah neuron output pada *Output Layer* adalah 1. Jumlah neuron pada *hidden layer* ditentukan secara random. Daftar arsitektur jaringan backpropagation dapat dilihat pada Tabel 2.

**Tabel 2. Arsitektur Resilient Backpropagation (RProp)**

No	Arsitektur	Keterangan
1.	3-3-1	Jumlah neuron input 3, Jumlah layer tersembunyi 3 neuron dan 1 neuron output
2.	3-4-1	Jumlah neuron input 3, Jumlah layer tersembunyi 4 neuron dan 1 neuron output
3.	3-5-1	Jumlah neuron input 3, Jumlah layer tersembunyi 5 neuron dan 1 neuron output

Pada Tabel 1. dan 2 menunjukkan dalam melakukan sebuah pengujian implementasi sistem simulasi hal yang perlu diperhatikan yaitu menentukan parameter-parameter jaringan agar nantinya prediksi yang dilakukan sesuai dengan yang diharapkan. Dalam tahap ini proses pengujian dilakukan dengan 3 sampel arsitektur yang sama dilakukan pada backpropagation standar dan Resilient backpropagation menggunakan aplikasi Matlab.

### 3.1. Spesifikasi Implementasi Perangkat Keras Dan Lunak

Spesifikasi implementasi perangkat keras dan lunak ini menjelaskan mengenai kebutuhan perangkat keras dan lunak yang dibutuhkan dalam implementasi sistem. Adapun spesifikasi implementasi perangkat keras yang digunakan dapat dilihat pada Tabel 3 dibawah ini:

**Tabel 3. Spesifikasi Implementasi Perangkat Keras**

No.	Perangkat Keras	Spesifikasi
1.	Processor	Intel Core i7-477HQ CPU 2.20 GHz
2.	Memori	16384 MB RAM DDR 3
3.	Harddisk SSD	256 GB
4.	Sistem Operasi	Windows 10 Pro 64-Bit
5.	Program	Matlab R2011b

### 3.2. Persiapan Data

Sebelum melakukan proses pengujian dengan menggunakan aplikasi Matlab R2011b. Tahapan penelitian ini dilakukan dengan persiapan data untuk dinormalisasi kemudian membagi komposisi pembagian data *training* dan data *testing*. Karena kesalahan

menentukan komposisi presentasi data training dan testing dapat mempengaruhi nilai akurasi yang diperoleh oleh karena itu pembagian presentasi jumlah data keduanya dari sebuah dataset menjadi salah satu faktor penentu besaran nilai akurasi. Adapun pembagian komposisi presentasi data training dan data testing dapat dilihat pada Gambar dibawah ini:

**Tabel 4.** Pembagian Komposisi Persentasi Data

No	Pembagian Data	
	Training	Testing
1.	25% = 25 Data	75% = 75 Data
2.	50% = 50 Data	50% = 50 Data
3.	75% = 75 Data	25% = 25 Data

Dapat dilihat dari Tabel 4 bahwa pembagian komposisi data pertama yaitu dengan 25% dengan 75% menunjukkan 25 data *training* dan 75 data testing dari 100 data yang diolah, kedua dengan 50% dengan 50% menunjukkan 50 data *training* dan 50 data testing dari 100 data yang diolah dan yang ketiga dengan 75% dengan 25% menunjukkan 75 data *training* dan 25 data testing dari 100 data yang diolah. Lebih jelasnya data dapat dilihat pada Tabel 5 berikut ini:

**Tabel 5.** Data Training dan Data Testing

Pola	X1	X2	X3	Target
1	0,5667	0,4692	0,7571	1
2	0,6333	0,5308	0,7286	1
3	0,4333	0,8385	0,7571	1
4	0,6333	0,4692	0,7286	1
5	0,7000	0,4692	0,7857	1
...	...	...	...	...
99	0,7000	0,5923	0,7571	1
100	0,5667	0,6231	0,7286	1

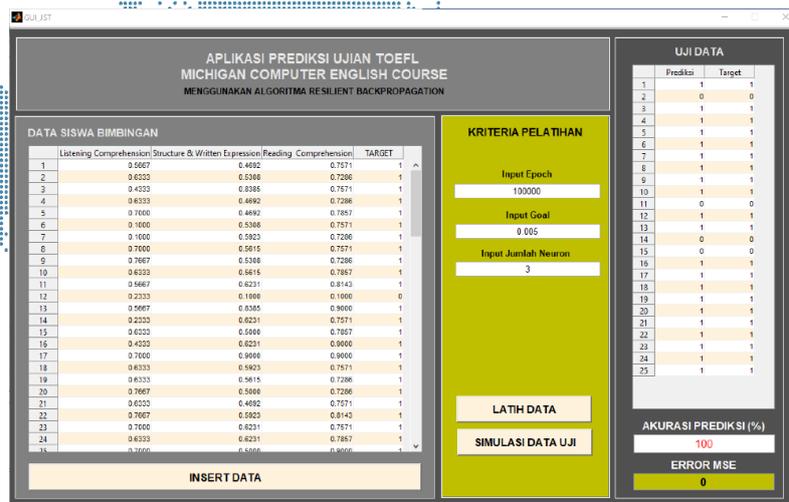
### 3.3. Hasil Pelatihan *Resilient Backpropagation (RProp)*

Setelah dilakukan proses persiapan data maka selanjutnya dilakukan proses pengujian *Resilient Backpropagation (RProp)* menggunakan GUI pada aplikasi Matlab R2011b dengan melakukan pengujian tiga komposisi pembagian data yang berbeda, adapun hasil rekapitulasi pengujian dapat dilihat pada Tabel 6 berikut ini:

**Tabel 6.** Pembagian Data

No	Pembagian Data		Akurasi <i>Testing Resilient Backpropagation</i>
	Training	Testing	
1.	25% = 25 Data	75% = 75 Data	99.25%
2.	50% = 50 Data	50% = 50 Data	100%
3.	75% = 75 Data	25% = 25 Data	100%

Hasil akurasi pada Tabel 6 didapat dari simulasi menggunakan aplikasi GUI yang telah dirancang menggunakan Matlab 2011b dengan pola 3-3-1. Pada penelitian ini kelompok pembagian data yang digunakan yaitu 75% data *training* dan 25% data *testing* data/dibagi menjadi dua dari 100 data yaitu data *training* yang berjumlah 75 dan data *testing* berjumlah 25 karena bernilai akurasi 100%. Dapat dilihat pada Gambar 1 berikut ini :



**Gambar 1.** Algoritma *Resilient Backpropagation (RProp)* dengan beberapa arsitektur yang berbeda dengan parameter yang sama

Pada pelatihan algoritma *Resilient Backpropagation (RProp)* dengan beberapa arsitektur yang berbeda dengan parameter yang sama, proses pelatihan dan pengujian selesai pada iterasi yang berbeda-beda juga, sedangkan akurasi seluruh percobaan bernilai maksimum 100%. dapat dilihat dan minimum 96%, dapat dilihat pada Tabel 7:

**Tabel 7.** Rekapitulasi Pengujian Resilient backpropagation

No	Arsitektur TrainRp	Epoch	Training	
			MSE	Akurasi (%)
1	3-3-1	14	0.00331	100%
2	3-4-1	7	0.00467	100%
3	3-5-1	6	0.00431	96%

#### 4. Kesimpulan

Kesimpulan dan saran dari hasil penelitian yang telah dilakukan dalam memprediksi kelulusan TOEFL menggunakan metode *Resilient Backpropagation (RProp)*. Adapun kesimpulan dari penelitian ini bahwa metode Resilient Backpropagation dapat diterapkan dalam memprediksi kelulusan TOEFL siswa bimbingan Michigan Computer English Course. Pembagian Presentasi data *Training* dan *Testing* mempengaruhi tingkat akurasi, sehingga pembagian komponen presentasi data yang tepat sangat berpengaruh terhadap hasil. Dari 3 percobaan hasil yang paling signifikan ditunjukkan pada percobaan dengan arsitektur 3-4-1 dengan nilai epoch 7 dengan akurasi 100% sedangkan arsitektur 3-5-1 dengan nilai epoch 6 dengan akurasi 96%. Dengan melihat hasil pengujian tersebut dapat diambil sebuah kesimpulan yaitu jika data training lebih kecil dari data testing maka akurasinya tidak mencapai 100% yaitu 99.25%, sedangkan jika data training lebih besar/samadengan data testing maka hasil akurasi mencapai 100%. Hal tersebut sangat relevan dengan pengertian Jaringan Saraf Tiruan (JST) yaitu Merupakan salah satu representasi buatan otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia sehingga semakin banyak melakukan pembelajaran maka akan semakin baik saat diuji.

#### Daftar Pustaka

- [1] H. Okprana, M. R. Lubis, and J. T. Hadinata, "Prediksi Kelulusan TOEFL Menggunakan Metode Resilient Backpropagation," *J. Edukasi dan Penelit. Inform.*, vol. 6, no. 2, p. 275, 2020, doi: 10.26418/jp.v6i2.41224.

- [2] S. P. Sinaga *et al.*, "Implementasi Jaringan Syaraf Tiruan Resilient Backpropagation dalam Memprediksi Angka Harapan Hidup Masyarakat Sumatera Utara," *J. Infomedia*, vol. 4, no. 2, 2019.
- [3] W. Saputra, J. T. Hardinata, and A. Wanto, "Implementation of Resilient Methods to Predict Open Unemployment in Indonesia According to Higher Education Completed," *J. Inf. Technol. Educ. Res.*, vol. 3, no. 1, pp. 163–174, 2019, doi: 10.31289/JITE.V3I1.2704.
- [4] B. Poerwanto and F. Fajriani, "Resilient Backpropagation Neural Network on Prediction of Poverty Levels in South Sulawesi," *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 20, no. 1, pp. 11–18, 2020, doi: 10.30812/matrik.v20i1.726.
- [5] W. Saputra, J. T. Hardinata, and A. Wanto, "Penerapan Metode Resilient dalam Menentukan Model Arsitektur Terbaik untuk Prediksi Pengangguran Terbuka di Indonesia," *Semin. Nas. Apl. Teknol. Inf.*, pp. 21–29, 2019.
- [6] Y. Yusran, "Implementasi Jaringan Syaraf Tiruan (Jst) Untuk Memprediksi Hasil Nilai Un Menggunakan Metode Backpropagation," *J. Ipteks Terap.*, vol. 9, no. 4, pp. 269–275, 2016, doi: 10.22216/jit.2015.v9i4.571.
- [7] I. N. T. Adnyana, I. G. P. S. Wijaya, and M. A. Albar, "Jaringan Syaraf Tiruan Model Backpropagation untuk Peramalan Suhu Minimum dan Maksimum, Kelembaban, Tekanan Udara, Jumlah Hari Hujan, dan Curah Hujan Bulanan di Kota Mataram," *J. Comput. Sci. Informatics Eng.*, vol. 3, no. 2, 2019, doi: 10.29303/jcosine.v3i2.259.
- [8] S. R. Jannah, F. Fithria, S. Novitayani, C. Husna, and J. Juanita, "Upaya Peningkatan Kelulusan TOEFL Mahasiswa dengan Metode Self Help Group (SHG)," *Idea Nurs. J.*, vol. 10, no. 1, pp. 44–50, 2019, doi: doi.org/10.52199/inj.v10i1.16549.
- [9] I. Irmayani and A. M. Sudirman, "Implementasi Aplikasi Tes TOEFL Berbasis Desktop," *Pros. Semant.*, vol. 2, no. 1, pp. 169–174, 2019, [Online]. Available: <https://journal.uncp.ac.id/index.php/semantik/article/view/1505/1313>
- [10] Agus Perdana Windarto, "Implementasi Jst Dalam Menentukan Kelayakan Nasabah Pinjaman Kur Pada Bank Mandiri Mikro Serbelawan Dengan Metode Backpropogation," *J-SAKTI (Jurnal Sains Komput. dan Inform.*, vol. 1, no. 1, pp. 12–23, 2017, doi: 10.7910/DVN/BRQ1OX.
- [11] S. Solikhun, M. Safii, and A. Trisno, "Jaringan Saraf Tiruan Untuk Memprediksi Tingkat Pemahaman Sisiwa Terhadap Matapelajaran Dengan Menggunakan Algoritma Backpropagation," *J-SAKTI (Jurnal Sains Komput. dan Inform.*, vol. 1, no. 1, p. 24, 2017, doi: 10.30645/j-sakti.v1i1.26.
- [12] R. Prasetya, "Implementasi Jaringan Syaraf Tiruan Backpropagation untuk Memprediksi Ketinggian Air (Studi Kasus: Sungai Ciliwung)," *STRING (Satuan Tulisan Ris. dan Inov. Teknol.*, vol. 1, no. 3, p. 297, 2017, doi: 10.30998/string.v1i3.1558.
- [13] "View of Komparasi Algoritma Machine Learning untuk Penentuan Performance Terbaik Pada Prediksi Produksi Tanaman Jahe di Indonesia." <https://www.prosiding.politeknikcendana.ac.id/index.php/sanistek/article/view/70/52> (accessed Feb. 08, 2023).
- [14] K. Onggrono and E. B. Nababan, "Analisis Penggunaan Parallel Processing Multithreading Pada Resilient Backpropagation".
- [15] W. Saputra, T. Tulus, M. Zarlis, R. W. Sembiring, and D. Hartama, "Analysis Resilient Algorithm on Artificial Neural Network Backpropagation," *J. Phys. Conf. Ser.*, vol. 930, no. 1, pp. 0–6, 2017, doi: 10.1088/1742-6596/930/1/012035.
- [16] K. Onggrono, "Analysis Resilient Algorithm on Artificial Neural Network Backpropagation," *J. Phys. Conf. Ser.*, vol. 930, no. 1, 2017, doi: 10.1088/1742-6596/930/1/012035.