

Optimasi Fungsi Pembelajaran Jaringan Saraf Tiruan dalam Meningkatkan Akurasi pada Prediksi Ekspor Kopi Menurut Negara Tujuan Utama

Ihda Innar Ridho^{1,*}, Anak Agung Gede Bagus Ariana², Agus Perdana Windarto³

¹Universtias Islam Kalimantan Muhammad Arsyad Al Banjari, Banjarmasin, Indonesia

²Prodi Sistem Komputer, Institut Bisnis dan Teknologi Indonesia, Denpasar, Indonesia

³Prodi Sistem Informasi, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: ^{1,*}ihdaridho@uniska-bjm.ac.id, ²gungariana@instiki.ac.id, ³agus.perdana@amikunasbangsa.ac.id

Email Penulis Korespondensi: ihdaridho@uniska-bjm.ac.id

Submitted: 16/03/2023; Accepted: 31/03/2023; Published: 31/03/2023

Abstrak—Dalam proses pembelajaran yang dilakukan Backpropagation fungsi pembelajaran merupakan hal yang penting dalam menemukan hasil yang optimal. Penelitian ini bertujuan untuk mengoptimasi fungsi pembelajaran jaringan saraf tiruan dalam meningkatkan akurasi pada prediksi ekspor kopi menurut negara tujuan utama sebagai objek penelitian. Penelitian ini menerapkan fungsi pembelajaran untuk bobot-bobot yang terdapat di Matlab yaitu Gradient Descent dengan Adaptive Learning Rate (traingda), Gradient Descent dengan Momentum (traingdm), dan Gradient Descent dengan Momentum dan Adaptive Learning Rate (traingdx) dengan menggunakan beberapa hidden layer yakni 15,30 dan 45. Berdasarkan serangkaian uji coba yang dilakukan, hasil penelitian menunjukkan dengan mengimplementasikan fungsi pembelajaran Gradient Descent dengan Adaptive Learning Rate (traingda) dengan hidden layer 30 mampu untuk pelatihan jaringan saraf dengan tingkat keoptimalan lebih baik, melakukan iterasi sebanyak 143 kali yang menghasilkan akurasi kebenaran sebesar 83%. Jika dibandingkan dengan penggunaan fungsi pembelajaran lainnya yang hanya bertahan dengan akurasi tidak lebih dari 78%. Secara umum, disimpulkan bahwa optimasi fungsi pembelajaran Gradient Descent dengan Adaptive Learning Rate (traingda) dapat diterapkan untuk prediksi ekspor kopi menurut negara tujuan utama, karena proses iterasi yang dilakukan untuk pencapaian konvergensi dalam meningkatkan akurasi berkinerja baik. Kesimpulannya, optimasi fungsi pembelajaran jaringan saraf tiruan dapat digunakan sebagai alat prediksi yang efektif dalam memprediksi ekspor kopi ke negara tujuan utama.

Kata Kunci: Fungsi Pembelajaran; Backpropagation; Matlab; Jaringan Saraf Tiruan; Akurasi

Abstract—In the learning process carried out by Backpropagation the learning function is important in finding optimal results. This study aims to optimize the learning function of artificial neural networks in increasing the accuracy of coffee export predictions according to the main destination countries as research objects. This study applies the learning function to weights in Matlab, namely Gradient Descent with Adaptive Learning Rate (traingda), Gradient Descent with Momentum (traingdm), and Gradient Descent with Momentum and Adaptive Learning Rate (traingdx) using several hidden layers, namely 15,30 and 45. Based on a series of trials conducted, the results of the study show that by implementing the Gradient Descent learning function with an Adaptive Learning Rate (traingda) with a hidden layer of 30 it is capable of training neural networks with a better level of optimization, performing 143 iterations which produces a truth accuracy of 83%. When compared with the use of other learning functions that only last with an accuracy of no more than 78%. In general, it can be concluded that the optimization of the Gradient Descent learning function with Adaptive Learning Rate (traingda) can be applied to predict coffee exports according to the main destination countries, because the iterative process carried out to achieve convergence in increasing accuracy performs well.

Keywords: Learning Functions; Backpropagation; Matlab; Neural Networks; Accuracy

1. PENDAHULUAN

Indonesia merupakan salah satu produsen kopi terbesar di dunia dengan komoditas kopi menjadi salah satu andalan ekspor nasional. Ekspor kopi dari Indonesia memiliki peran penting dalam perekonomian nasional dan memberikan kontribusi yang signifikan terhadap pendapatan devisa negara [1], [2]. Namun, untuk meningkatkan daya saing ekspor kopi Indonesia, diperlukan teknik prediksi yang efektif untuk mengidentifikasi negara tujuan utama ekspor kopi dan memperkirakan volume ekspor kopi yang dibutuhkan oleh pasar [3]. Penelitian ini dilakukan untuk mengoptimalkan fungsi pembelajaran jaringan saraf tiruan dalam meningkatkan akurasi prediksi ekspor kopi menurut negara tujuan utama. Tujuannya adalah untuk memberikan alat prediksi yang efektif bagi para pelaku industri kopi dalam mengambil keputusan bisnis terkait ekspor kopi. Pada saat ini, teknik prediksi ekspor kopi masih menggunakan metode-metode konvensional seperti regresi [4], [5], yang belum optimal dalam memprediksi hasil ekspor kopi. Hal ini disebabkan oleh kompleksitas data ekspor kopi yang sangat tinggi. Oleh karena itu, diperlukan teknik prediksi yang lebih efektif seperti jaringan saraf tiruan.

Jaringan saraf memiliki kemampuan yang sangat baik untuk mengekstrak informasi dari data yang kompleks atau tidak tepat, dapat memecahkan masalah yang tidak terstruktur dan sulit didefinisikan [6], dapat belajar dari pengalaman, dan ketika tidak ada kepastian tetapi pengetahuan dapat diperoleh [7], [8], digeneralisasikan, dan diekstraksi [9]. Karena pemodelan ini bersifat dinamis dan *real-time*, maka metode prediksi yang paling banyak digunakan adalah jaringan saraf tiruan [7]. Jaringan Saraf Tiruan (JST) merupakan cabang pemodelan yang kuat, yang dapat memfasilitasi pembuatan hubungan antara parameter masukan dan keluaran melalui bobot yang sesuai dan fungsi aktivasi [10]. Data yang tidak lengkap dan ketepatan penggunaan fungsi-fungsi pada jaringan saraf tiruan yang digunakan cepat atau lambat dapat mempengaruhi kinerja proses pelatihan. Namun penggunaan data yang tidak

lengkap (*missing data*) dapat menyebabkan kesalahan pada hasil pelatihan, sehingga diperlukan koreksi terhadap data yang hilang.

Backpropagation [4], [11]–[14] merupakan salah satu metode JST dimana cara kerjanya adalah melatih jaringan untuk mencapai keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan dan kemampuan jaringan untuk merespons dengan benar pola masukan yang serupa dengan pola yang digunakan selama pelatihan [15]. Metode ini juga termasuk dalam arsitektur jaringan saraf tiruan dengan proses pembelajaran maju dan koreksi kesalahan secara mundur. *Backpropagation* memiliki bermacam-macam fungsi pembelajaran untuk bobot-bobot yang terdapat di *Matlab* yaitu *Gradient Descent* dengan *Momentum* (*traingdm*), *Gradient Descent* dengan *Adaptive Learning Rate* (*traingda*), *Resilient Backpropagation* (*traingrp*) [16], *Gradient Descent* dengan *Momentum* dan *Adaptive Learning Rate* (*traingdx*) dan lain sebagainya. Yang mana fungsi-fungsi tersebut memiliki hasil yang berbeda-beda dalam melakukan pembelajaran. Dalam proses pembelajaran yang dilakukan *Backpropagation* fungsi pembelajaran merupakan hal yang penting dalam menemukan hasil yang optimal. Kelemahan dari fungsi pembelajaran standar dari *backpropagation* adalah bahwa ia dapat mengalami masalah konvergensi lambat dan kemungkinan terjebak dalam optimum lokal yang tidak optimal. Selain itu, fungsi aktivasi yang digunakan dalam *backpropagation* juga dapat mempengaruhi performa jaringan saraf tiruan [17]. Untuk mengatasi kelemahan tersebut, teknik optimasi dengan mengubah fungsi pembelajaran dapat digunakan untuk memperbaiki performa *backpropagation* [15], [16]. Dengan menggunakan teknik optimasi tersebut, *backpropagation* dapat memperoleh solusi yang lebih optimal dan akurat [16], [18]–[21] dalam memprediksi ekspor kopi menurut negara tujuan utama. Namun, optimasi juga dapat menghasilkan waktu komputasi yang lebih lama dan membutuhkan penyesuaian parameter yang tepat untuk memperoleh hasil yang optimal. Oleh karena itu, pemilihan teknik optimasi yang tepat dan parameter-parameter yang optimal sangat penting dalam meningkatkan performa *backpropagation*.

2. METODOLOGI PENELITIAN

Backpropagation merupakan teknik yang digunakan dalam pelatihan jaringan saraf tiruan dengan menyesuaikan bobot dan bias di setiap lapisan jaringan berdasarkan perbedaan antara hasil prediksi dan nilai target [4], [13], [22]. Teknik ini memperbaiki nilai bobot dan bias secara iteratif menggunakan turunan parsial dari fungsi kerugian (*loss function*) terhadap parameter-parameter jaringan. Proses ini dilakukan berulang kali hingga nilai kerugian yang dihasilkan mencapai nilai minimum [23], [24]. Terdapat beberapa jenis fungsi pembelajaran pada jaringan saraf tiruan dengan metode *backpropagation* [25]–[27], antara lain:

- a. *Gradient Descent* dengan *Momentum* (*traingdm*) Pada metode ini, digunakan momentum untuk membantu menentukan kecepatan pergerakan bobot. Rumus yang digunakan untuk mengupdate bobot pada setiap iterasi adalah sebagai berikut:

$$\Delta w(n) = \alpha * \Delta w(n-1) - \eta * \nabla E(n) \quad w(n) = w(n-1) + \Delta w(n) \quad (1)$$

Keterangan:

α adalah momentum rate.

η adalah learning rate.

$\nabla E(n)$ adalah gradien pada iterasi ke-n.

$\Delta w(n-1)$ adalah perubahan bobot pada iterasi sebelumnya.

- b. *Gradient Descent* dengan *Adaptive Learning Rate* (*traingda*) Pada metode ini, digunakan learning rate yang dapat disesuaikan dengan kondisi pada setiap iterasi. Rumus yang digunakan untuk mengupdate bobot pada setiap iterasi adalah sebagai berikut:

$$w(n) = w(n-1) - \eta(n) * \nabla E(n) \quad (2)$$

Keterangan:

$\eta(n)$ adalah learning rate pada iterasi ke-n.

$\nabla E(n)$ adalah gradien pada iterasi ke-n.

- c. *Resilient Backpropagation* (*traingrp*) Pada metode ini, digunakan adaptif learning rate dan momentum rate yang disesuaikan dengan nilai gradien pada iterasi sebelumnya. Rumus yang digunakan untuk mengupdate bobot pada setiap iterasi adalah sebagai berikut:

$$\Delta w(n) = -\eta(n) * \nabla E(n) + \alpha * \Delta w(n-1) \quad w(n) = w(n-1) + \Delta w(n) \quad (3)$$

Keterangan:

$\eta(n)$ adalah learning rate pada iterasi ke-n.

α adalah momentum rate.

$\nabla E(n)$ adalah gradien pada iterasi ke-n.

$\Delta w(n-1)$ adalah perubahan bobot pada iterasi sebelumnya.

- d. *Gradient Descent* dengan *Momentum* dan *Adaptive Learning Rate* (*traingdx*) Pada metode ini, digunakan momentum dan adaptive learning rate. Rumus yang digunakan untuk mengupdate bobot pada setiap iterasi adalah sebagai berikut:

$$\Delta w(n) = \alpha * \Delta w(n-1) - \eta(n) * \nabla E(n) \quad w(n) = w(n-1) + \Delta w(n) \tag{4}$$

Keterangan:

α adalah momentum rate.

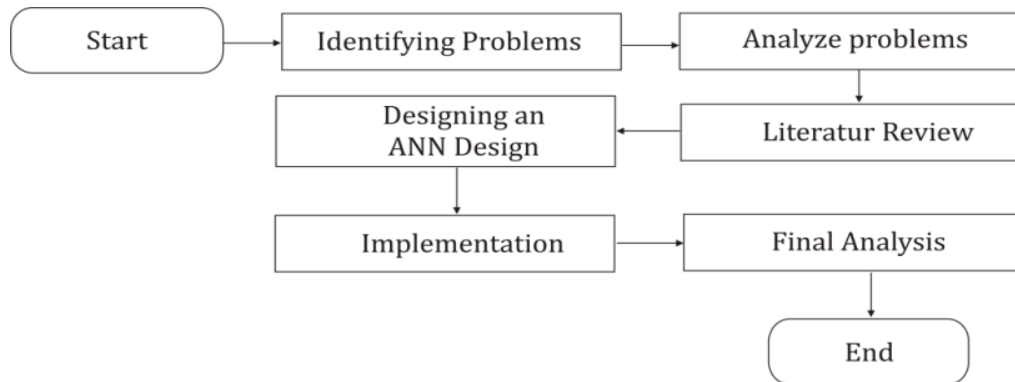
$\eta(n)$ adalah learning rate pada iterasi ke-n.

$\nabla E(n)$ adalah gradien pada iterasi ke-n.

$\Delta w(n-1)$ adalah perubahan bobot pada iterasi sebelumnya

2.1 Tahapan Penelitian

Berikut merupakan tahapan penelitian yang dilakukan seperti tertuang dalam kerangka kerja penelitian pada Gambar 1 berikut:



Gambar 1. Kerangka Kerja Penelitian

- Mendefinisikan Masalah
Permasalahan yang akan didefinisikan pada poin ini adalah permasalahan apa saja yang terjadi pada saat menerapkan fungsi pembelajaran algoritma *backpropagation* pada objek penelitian.
- Menganalisa Masalah
Melalui analisis, masalah yang teridentifikasi dapat dipahami dengan baik. Permasalahannya sekarang adalah menganalisis fungsi pembelajaran *backpropagation* dalam prediksi ekspor kopi menurut negara tujuan utama.
- Studi Literatur
Penelitian kepustakaan berfungsi untuk menyelidiki dan melengkapi informasi tentang fungsi umpan balik peneliti, sumber pustaka adalah buku, majalah, paper, artikel ilmiah serta *website* dan literatur lain yang menyertainya.
- Analisa Data
Dataset yang digunakan bersumber dari Dokumen Kapabeaan Ditjen Bea dan Cukai di situs resmi Badan Pusat Statistik dalam bentuk variabel dan memiliki nilai yang tidak seragam, maka perlu dilakukan normalisasi. Normalisasi dilakukan untuk menyesuaikan nilai data dengan *range* fungsi aktivasi yang digunakan dalam jaringan. Pada penelitian ini menggunakan fungsi aktivasi *sigmod biner* maka data diubah menggunakan normalisasi ke bilangan dengan *interval* 0-1.

$$x' = \frac{0,8(x-a)}{b-a} + 0,1 \tag{5}$$

Di mana :

x' = Hasil konversi data;

x = Nilai yang akan dikonversi;

a = Nilai minimum dari suatu kelompok data;

b = Nilai maksimum dari suatu kelompok data;

Berikut pada tabel 1 merupakan data ekspor kopi menurut negara tujuan utama

Tabel 1. Ekspor Kopi Menurut Negara Tujuan Utama (2016-2021)

Negara Tujuan	2016	2017	2018	2019	2020	2021
Jepang	35,351.9	29,503.0	30,360.3	25,587.8	23,471.4	27,297.0
Singapura	7,099.1	7,178.0	7,814.1	8,717.1	5,212.9	5,377.0
Malaysia	39,049.0	41,394.1	37,319.8	34,662.2	36,103.8	29,059.1
India	11,574.0	8,291.0	2,236.6	12,578.5	19,998.0	22,109.6
Mesir	21,142.7	24,039.6	29,307.8	34,285.0	32,536.7	48,521.3
Maroko	9,720.5	11,072.4	11,075.1	9,663.9	9,603.7	12,164.1
Aljazair	9,885.0	19,022.9	5,007.9	4,872.6	5,919.6	3,918.1
Amerika Serikat	67,309.2	63,237.6	52,083.5	58,666.2	54,473.7	57,694.0

Negara Tujuan	2016	2017	2018	2019	2020	2021
Inggris	18,355.8	21,937.5	7,555.1	18,923.5	21,349.5	12,259.5
Jerman	42,628.3	44,739.6	13,082.6	18,451.4	21,320.8	13,334.8
Italia	35,804.6	38,102.9	27,929.5	35,452.2	27,237.5	24,590.0
Rumania	282.0	1,207.8	1,076.0	1,140.0	585.6	509.4
Georgia	11,209.6	11,706.5	10,746.0	12,229.6	12,748.0	13,398.0
Belgia	12,152.7	13,156.2	6,207.0	16,259.6	14,758.1	14,434.0
Belanda	6,398.7	2,915.0	1,631.5	1,604.2	1,490.8	2,243.5
Denmark	248.7	57.2	62.6	38.2	75.5	41.3
Perancis	7,657.6	2,415.7	265.8	2,945.3	4,376.4	5,993.4
Lainnya	76,500.9	124,221.3	33,650.0	59,689.2	84,293.9	91,566.5

2.2 Model Arsitektur Jaringan

Tidak ada aturan standart yang mengharuskan penggunaan model arsitektur jaringan tertentu. Biasanya model arsitektur yang digunakan dimulai dengan nilai yang kecil dan berlanjut ke nilai yang lebih besar. Dalam hal ini digunakan 3 model arsitektur, antara lain : 3-15-1; 3-30-1; dan 3-45-1. *Input* (masukkan) = 3 ditentukan berdasarkan *input* tabel, nilainya tidak bisa diubah, karena telah ditetapkan di awal pada tabel. *Hidden layer* bisa diubah, bisa menggunakan 1 atau lebih *hidden layer*. Neuron *hidden layer* juga bisa diubah nilainya sesuai keinginan untuk mencari hasil terbaik. Sedangkan *output* = 1 ditentukan berdasarkan target pada masing-masing data yang hanya menampung satu nilai.

2.3 Implementasi

Pada Tahap ini dilakukan implementasi dari perancangan yang telah dibuat. Rancangan arsitektur akan diimplementasi dengan *tools* bantuan *Matlab 6.1*. Penelitian ini ada beberapa skenario yang akan dilakukan yaitu dengan melatih data pada beberapa bentuk arsitektur yang berbeda-beda pada masing-masing fungsi pembelajaran.

2.4 Analisis Hasil

Hasil *output* yang diperoleh harus dianalisis untuk mengetahui tingkat akurasi. Hasil pengujian menghasilkan pola trend yang dapat dianalisis. Pemodelan arsitektur akan ditinjau untuk melihat apakah cocok atau memecahkan masalah.

3. HASIL DAN PEMBAHASAN

Setelah data dinormalisasi maka dilakukan pelatihan dengan data yang ada, dan juga dilakukan pengujian terhadap Arsitektur Jaringan Saraf Tiruan dengan membandingkan fungsi pembelajaran di mana yang tingkat akurasi pengenalan pola yang paling sesuai atau mendekati dengan target. Untuk mengoptimalkan arsitektur *backpropagation*, harus menyelidiki bagaimana merancang parameter jaringan sehingga jumlah iterasi (*epoch*) yang dihasilkan relatif lebih kecil dan nilai keluaran mendekati target. Dalam melakukan pelatihan atau pembelajaran parameter yang digunakan adalah sebagai berikut.

```
>>net=newff(minmax(P),[Hidden,Target],{'tansig','logsig'},'traingda/traingdm/traingdx')
>>net.LW{1,1}
>>net.b{1}
>>net.LW{2,1}
>>net.b{2}
>>net.trainparam.epochs=1500000
>>net.trainparam.LR=0.1
>>net.trainparam.goal=0,001
>>net.trainparam.show=100
>>net=train(net,P,T)
```

Berikut adalah dataset training dan testing yang sudah dinormalisasi dengan menggunakan formula 5 seperti yang ditunjukkan pada tabel 2 dan 3 berikut:

Tabel 2. Data Hasil Normalisasi (*Training*)

Variabel	X1	X2	X3	Y
V1	0.3275	0.2898	0.2953	0.2646
V2	0.1455	0.1460	0.1501	0.1559
V3	0.3513	0.3664	0.3402	0.3231
V4	0.1743	0.1532	0.1142	0.1808
V5	0.2360	0.2546	0.2886	0.3206
V6	0.1624	0.1711	0.1711	0.1620



V7	0.1634	0.2223	0.1320	0.1311
V8	0.5334	0.5071	0.4353	0.4777
V9	0.2180	0.2411	0.1484	0.2217
V10	0.3744	0.3880	0.1840	0.2186
V11	0.3304	0.3452	0.2797	0.3281
V12	0.1016	0.1075	0.1067	0.1071
V13	0.1720	0.1752	0.1690	0.1785
V14	0.1780	0.1845	0.1397	0.2045
V15	0.1410	0.1185	0.1103	0.1101
V16	0.1014	0.1001	0.1002	0.1000
V17	0.1491	0.1153	0.1015	0.1187
V18	0.5926	0.9000	0.3165	0.4843

Data *training* menggunakan data ekspor kopi menurut negara tujuan utama tahun 2016-2018 sebagai *input* dan 2019 sebagai target. Sedangkan data *testing* menggunakan data ekspor kopi menurut negara tujuan utama tahun 2018-2020 sebagai *input* dan 2021 sebagai target seperti pada tabel berikut.

Tabel 3. Data Hasil Normalisasi (*Testing*)

Variabel	X3	X4	X5	Y
V1	0.3650	0.3233	0.3048	0.3383
V2	0.1680	0.1759	0.1452	0.1467
V3	0.4259	0.4026	0.4152	0.3537
V4	0.1192	0.2096	0.2745	0.2929
V5	0.3558	0.3993	0.3841	0.5238
V6	0.1965	0.1841	0.1836	0.2060
V7	0.1434	0.1423	0.1514	0.1339
V8	0.5549	0.6124	0.5758	0.6039
V9	0.1657	0.2651	0.2863	0.2068
V10	0.2140	0.2609	0.2860	0.2162
V11	0.3438	0.4095	0.3377	0.3146
V12	0.1091	0.1096	0.1048	0.1041
V13	0.1936	0.2066	0.2111	0.2168
V14	0.1539	0.2418	0.2287	0.2258
V15	0.1139	0.1137	0.1127	0.1193
V16	0.1002	0.1000	0.1003	0.1000
V17	0.1020	0.1254	0.1379	0.1521
V18	0.3938	0.6214	0.8364	0.9000

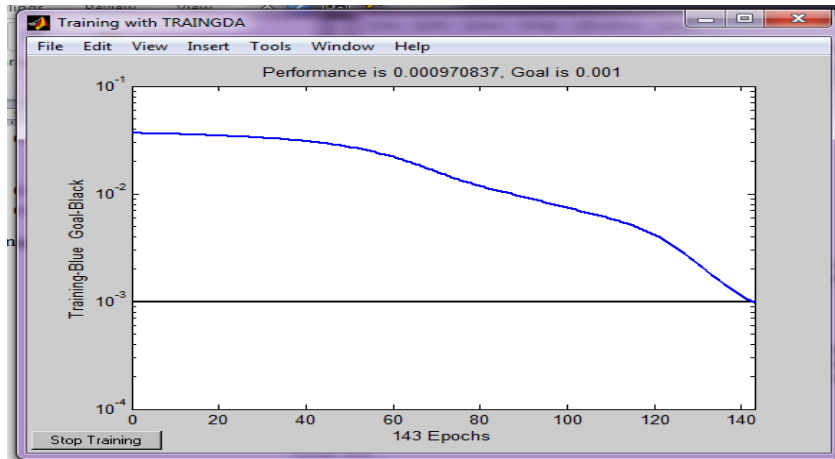
3.1. Analisis Hasil

Berikut merupakan rekapitulasi hasil yang diperoleh atas dilakukannya pelatihan dan pengujian dengan *Matlab 6.1* atas optimasi fungsi pembelajaran yang telah diimplementasikan.

Tabel 4. Rekapitulasi Optimasi Fungsi Pembelajaran

Fungsi Pembelajaran	Hidden layer	MSE Training	MSE Testing	Epoch	Akurasi
TRAINGDA	15	0.0029542239	0.0009849028	139	78%
	30	0.0009705550	0.0009227883	143	83%
	45	0.0009098117	0.0009860406	129	78%
TRAINGDM	15	0.0009998822	0.0010001739	5494	78%
	30	0.0010000906	0.0010005817	4721	78%
	45	0.0009995483	0.0010001983	18596	72%
TRAINGDx	15	0.0009770317	0.0009914417	135	67%
	30	0.0009648139	0.0009857422	118	78%
	45	0.0009824244	0.0009543217	124	78%

Berdasarkan Tabel 4, dapat dilihat bahwa fungsi pembelajaran yang paling optimal dalam meningkatkan akurasi pada prediksi ekspor kopi menurut negara tujuan utama adalah fungsi pembelajaran TRAINGDA atau *Gradient Descent* dengan *Adaptive Learning Rate* dengan *hidden layer* 30, melakukan iterasi sebanyak 143 kali yang menghasilkan akurasi kebenaran sebesar 83%. Adapun detail dari implementasi fungsi pembelajaran TRAINGDA dengan *hidden layer* 30 adalah sebagai berikut.



Gambar 2. Pelatihan fungsi pembelajaran *traingda* dengan *hidden layer* 30

Berikut hasil *training* dan *testing* fungsi pembelajaran *traingda* dengan *hidden layer* 30.

Tabel 5. Pelatihan fungsi pembelajaran *traingda* dengan *hidden layer* 30

No	Real	Target	ANN 3-30-1 TRAINGDA		
			Output	Error	SSE
1	V1	0.2646	0.3030	-0.0384	0.0014745600
2	V2	0.1559	0.1276	0.0283	0.0008008900
3	V3	0.3231	0.3361	-0.0130	0.0001690000
4	V4	0.1808	0.1887	-0.0079	0.0000624100
5	V5	0.3206	0.3282	-0.0076	0.0000577600
6	V6	0.1620	0.1236	0.0384	0.0014745600
7	V7	0.1311	0.1203	0.0108	0.0001166400
8	V8	0.4777	0.4822	-0.0045	0.0000202500
9	V9	0.2217	0.1948	0.0269	0.0007236100
10	V10	0.2186	0.2369	-0.0183	0.0003348900
11	V11	0.3281	0.2810	0.0471	0.0022184100
12	V12	0.1071	0.1308	-0.0237	0.0005616900
13	V13	0.1785	0.1348	0.0437	0.0019096900
14	V14	0.2045	0.1711	0.0334	0.0011155600
15	V15	0.1101	0.1543	-0.0442	0.0019536400
16	V16	0.1000	0.1379	-0.0379	0.0014364100
17	V17	0.1187	0.1736	-0.0549	0.0030140100
18	V18	0.4843	0.4894	-0.0051	0.0000260100
Total					0.0174699900
MSE					0.0009705550

Tabel 6. Pengujian fungsi pembelajaran *traingda* dengan *hidden layer* 30

No	Real	Target	ANN 3-30-1 TRAINGDA			Hasil
			Output	Error	SSE	
1	V1	0.3383	0.3407	-0.0024	0.0000057600	T
2	V2	0.1467	0.1606	-0.0139	0.0001932100	T
3	V3	0.3537	0.4158	-0.0621	0.0038564100	F
4	V4	0.2929	0.2559	0.0370	0.0013690000	T
5	V5	0.5238	0.4391	0.0847	0.0071740900	F
6	V6	0.2060	0.1930	0.0130	0.0001690000	T
7	V7	0.1339	0.1356	-0.0017	0.0000028900	T
8	V8	0.6039	0.6072	-0.0033	0.0000108900	T
9	V9	0.2068	0.2311	-0.0243	0.0005904900	T
10	V10	0.2162	0.2308	-0.0146	0.0002131600	T
11	V11	0.3146	0.3199	-0.0053	0.0000280900	T
12	V12	0.1041	0.1071	-0.0030	0.0000090000	T
13	V13	0.2168	0.2194	-0.0026	0.0000067600	T
14	V14	0.2258	0.2469	-0.0211	0.0004452100	T
15	V15	0.1193	0.1158	0.0035	0.0000122500	T

16	V16	0.1000	0.1015	-0.0015	0.0000022500	T
17	V17	0.1521	0.1508	0.0013	0.0000016900	T
18	V18	0.9000	0.9502	-0.0502	0.0025200400	F
Total					0.0166101900	83
MSE					0.0009227883	

Berdasarkan rujukan Tabel 4, maka Tabel 4 dan 5 adalah details dari fungsi pembelajaran terbaik yakni TRAINGDA dengan akurasi pengujian 83%. Fungsi ini mengalahkan perhitungan akurasi dari fungsi pembelajaran standar dengan akurasi dibawah 80% (Tabel 4).

4. KESIMPULAN

Berdasarkan penelitian yang dilakukan, dapat disimpulkan bahwa optimasi fungsi pembelajaran jaringan saraf tiruan dengan metode backpropagation merupakan teknik yang efektif dalam meningkatkan akurasi prediksi ekspor kopi menurut negara tujuan utama. Dalam penelitian ini, teknik optimasi yang digunakan adalah fungsi pembelajaran *Gradient Descent dengan Adaptive Learning Rate* (TRAINGDA) yang berhasil meningkatkan performa jaringan saraf tiruan dalam memprediksi ekspor kopi. Dibandingkan dengan fungsi pembelajaran TRAINGDM dan TRAINGDX, penggunaan jaringan saraf tiruan mampu memberikan hasil prediksi yang lebih akurat. Secara details fungsi pembelajaran TRAINGDA dengan *hidden layer* 30 mampu untuk pelatihan jaringan saraf dengan tingkat keoptimalan lebih baik, melakukan iterasi sebanyak 143 kali yang menghasilkan akurasi kebenaran sebesar 83%. Jika dibandingkan dengan penggunaan fungsi pembelajaran lainnya yang hanya menghasilkan akurasi sebesar 78%. Namun, meskipun teknik ini menunjukkan hasil yang positif dalam penelitian ini, perlu diingat bahwa hasil prediksi tidak selalu akurat 100% karena prediksi hanya didasarkan pada data historis. Oleh karena itu, para pelaku industri kopi harus tetap memperhatikan faktor-faktor lain seperti kondisi pasar dan regulasi yang dapat mempengaruhi ekspor kopi ke negara tujuan utama.

REFERENCES

- [1] R. Utrilla-Catalan, R. Rodríguez-Rivero, V. Narvaez, V. Díaz-Barcos, M. Blanco, and J. Galeano, "Growing Inequality in the Coffee Global Value Chain: A Complex Network Assessment," *Sustainability* (Switzerland), vol. 14, no. 2, pp. 1–27, 2022, doi: 10.3390/su14020672.
- [2] N. A. Ramadhanty, U.- Farouk, and S.- Poerbo, "The Influence of International Coffee Prices and Rupiah Exchange Rate on Export Volume of Coffee in Central Java," *JOBS (Jurnal Of Business Studies)*, vol. 7, no. 1, p. 15, 2022, doi: 10.32497/jobs.v7i1.3633.
- [3] F. S. Islami, P. K. Prasetyanto, and A. D. Setiawan, "Analysis of determinants of coffee exports in Indonesia Fitrah," *INOVASI: Jurnal Ekonomi, Keuangan dan Manajemen*, vol. 18, no. (Special Issue), pp. 61–67, 2022, doi: 10.29264/jinv.v18i0.11239.
- [4] 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.
- [5] A. Wanto et al., "Model of Artificial Neural Networks in Predictions of Corn Productivity in an Effort to Overcome Imports in Indonesia," *Journal of Physics: Conference Series*, vol. 1339, no. 1, 2019, doi: 10.1088/1742-6596/1339/1/012057.
- [6] A. Perdana, S. Defit, and A. Wanto, "Optimalisasi Parameter dengan Cross Validation dan Neural Back-propagation Pada Model Prediksi Pertumbuhan Industri Mikro dan Kecil," *Jurnal Sistem Informasi Bisnis*, vol. 01, no. 11, pp. 34–42, 2021, doi: 10.21456/vol11iss1pp34-42.
- [7] D. N. Agus Perdana Windarto, M. S. H. Anjar Wanto, Frinto Tambunan, M. R. L. Muhammad Noor Hasan Siregar, and D. N. Solikhun, Yusra Fadhillah, *Jaringan Saraf Tiruan: Algoritma Prediksi dan Implementasi*, vol. 53, no. 9, 2019.
- [8] E. Kurniawan, H. Wibawanto, and D. A. Widodo, "Implementasi Metode Backpropagation dengan Inisialisasi Bobot Nguyen Widrow untuk Peramalan Harga Saham," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 1, p. 49, 2019, doi: 10.25126/jtiik.201961904.
- [9] Z. Fitri, "Analisis Error dan Epoch dengan Pengembangan Adaptive Learning Rate dan Parameter Momentum pada Metode Backpropagation," vol. 3, no. 2, 2018.
- [10] A. Kaab, M. Sharifi, H. Mobli, A. Nabavi-Pelesarai, and K. wing Chau, "Combined life cycle assessment and artificial intelligence for prediction of output energy and environmental impacts of sugarcane production," *Science of the Total Environment*, vol. 664, pp. 1005–1019, 2019, doi: 10.1016/j.scitotenv.2019.02.004.
- [11] S. Pohan, B. Warsito, and S. Suryono, "Backpropagation artificial neural network for prediction plant seedling growth," *Journal of Physics: Conference Series*, vol. 1524, no. 1, 2020, doi: 10.1088/1742-6596/1524/1/012147.
- [12] S. Amin, "Backpropagation – Artificial Neural Network (BP-ANN): Understanding gender characteristics of older driver accidents in West Midlands of United Kingdom," *Safety Science*, vol. 122, no. July 2019, p. 104539, 2020, doi: 10.1016/j.ssci.2019.104539.
- [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] H. Pratiwi et al., "Sigmoid Activation Function in Selecting the Best Model of Artificial Neural Networks," *Journal of Physics: Conference Series*, vol. 1471, no. 1, 2020, doi: 10.1088/1742-6596/1471/1/012010.
- [15] A. Fagustina, Y. Palgunadi, and Wiharto, "Pengaruh Fungsi Pembelajaran Terhadap Kinerja Pelatihan Jaringan Syaraf Tiruan Backpropagation," *Universitas Sebelas Maret*, vol. 3, pp. 1–10, 2014.



- [16] F. Damayanti, “Optimasi Fungsi Pembelajaran Backpropagation dalam Mengklasifikasikan Pasien Kanker Paru Pasca Operasi,” vol. 15, no. 1, pp. 2580–2582, 2022.
- [17] A. Wanto, S. Defit, and A. Perdana Windarto, “Algoritma Fungsi Pelatihan pada Machine Learning berbasis ANN untuk Peramalan Fenomena Bencana,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, pp. 254–264, 2021, doi: 10.29207/resti.v5i2.3031.
- [18] K. F. Irnanda, A. P. Windarto, and I. S. Damanik, “Optimasi Particle Swarm Optimization Pada Peningkatan Prediksi dengan Metode Backpropagation Menggunakan Software RapidMiner,” *Jurnal Riset Komputer*, vol. 9, no. 1, pp. 122–130, 2022, doi: 10.30865/jurikom.v9i1.3836.
- [19] A. Wanto, “Optimasi Prediksi Dengan Algoritma Backpropagation Dan Conjugate Gradient Beale-Powell Restarts,” *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 03, no. 03, pp. 370–380, 2017.
- [20] A. Wanto, “Optimasi Prediksi Dengan Algoritma Backpropagation Dan Conjugate Gradient Beale-Powell Restarts,” *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 3, no. 3, pp. 370–380, 2018, doi: 10.25077/teknosi.v3i3.2017.370-380.
- [21] 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.
- [22] A. P. Windarto, “Implementasi JST Dalam Menentukan Kelayakan Nasabah Pinjaman KUR Pada Bank Mandiri Mikro Serbelawan Dengan Metode Backpropagation,” *J-SAKTI (Jurnal Sains Komputer dan Informatika)*, vol. 1, no. 1, p. 12, 2017, doi: 10.30645/j-sakti.v1i1.25.
- [23] 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.
- [24] Y. A. Lesnussa, C. G. Mustamu, F. Kondo Lembang, and M. W. Talakua, “Application of Backpropagation Neural Networks in Predicting Rainfall Data in Ambon City,” *International Journal of Artificial Intelligence Research*, vol. 2, no. 2, 2018, doi: 10.29099/ijair.v2i2.59.
- [25] A. R. Naik, A. V. Deorankar, and P. B. Ambhore, “Rainfall Prediction based on Deep Neural Network: A Review,” *2nd International Conference on Innovative Mechanisms for Industry Applications, ICIMIA 2020 - Conference Proceedings*, no. Icimia, pp. 98–101, 2020, doi: 10.1109/ICIMIA48430.2020.9074892.
- [26] I. Oktanisa and A. A. Supianto, “Perbandingan Teknik Klasifikasi Dalam Data Mining Untuk Bank Direct Marketing,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 5, p. 567, 2018, doi: 10.25126/jtiik.201855958.
- [27] A. Wanto, J. Na’am, Yuhandri, A. P. Windarto, and Mesran, “Analisis Penurunan Gradien dengan Kombinasi Fungsi Aktivasi pada Algoritma JST untuk Pencarian Akurasi Terbaik,” *Jurnal Media Informatika Budidarma*, vol. 4, no. 2018, pp. 1197–1205, 2020, doi: 10.30865/mib.v4i4.2509.