

JST: Prediksi Perkembangan Produksi Tanaman Sayuran Dalam Upaya Pemenuhan Gizi Masyarakat dengan Algoritma Resilient

Azwar Anas Manurung^{1*}, Indra Satria², Anjar Wanto³

^{1,2}Program Studi Agroteknologi Fakultas Pertanian, Universitas Asahan, Kisaran, Indonesia

³ STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: ^{1*}anasazwar63@yahoo.com, ²indrasatria87861@gmail.com, ³anjarwanto@ieee.org

Abstract

Vegetable plants are very important in human life because they have a significant role as a source of nutrition and fulfillment of community nutrition. Therefore it is important to predict the production of vegetable crops. This study will use the Resilient algorithm which is one of the algorithms from Artificial Neural Networks (ANN) which is commonly used to predict data. This study uses times series data on vegetable crop production in North Sumatra Province from 2013 to 2022, obtained from the Indonesian Central Statistics Agency (BPS) website. The research topic will be analyzed using 5 ANN models, including: 8-8-1, 8-16-1, 8-24-1, 8-32-1 and 8-40-1. Based on the analysis results, model 8-32-1 was chosen as the best model, because it has an accuracy rate of 89% (the highest compared to other models). The results showed that the Resilient algorithm was able to predict vegetable crop production well. This research has important implications in supporting the sustainability of agricultural and food systems by providing information on developments in vegetable crop production to help farmers, producers and governments plan agricultural activities more effectively.

Keywords: ANN, Production, Vegetable Crops, Community Nutrition, Resilient

Abstrak

Tanaman sayuran sangat penting dalam kehidupan manusia karena memiliki peran yang signifikan sebagai sumber nutrisi dan pemenuhan gizi masyarakat. Oleh sebab itu penting dilakukan prediksi terhadap produksi tanaman sayuran. Penelitian ini akan menggunakan algoritma Resilient yang merupakan salah satu algoritma dari Jaringan Saraf Tiruan (JST) yang biasa digunakan untuk melakukan prediksi data. Penelitian ini menggunakan data times series produksi tanaman sayuran di Provinsi Sumatera Utara tahun 2013 hingga tahun 2022, yang diperoleh dari website Badan Pusat Statistik Indonesia (BPS). Topik penelitian akan dianalisis menggunakan 5 model JST, diantaranya: 8-8-1, 8-16-1, 8-24-1, 8-32-1 dan 8-40-1. Berdasarkan hasil analisis, model 8-32-1 terpilih sebagai model terbaik, karena memiliki tingkat akurasi sebesar 89% (Tertinggi dibandingkan model lain). Hasil penelitian menunjukkan bahwa algoritma Resilient mampu melakukan prediksi produksi tanaman sayuran dengan baik. Penelitian ini memiliki implikasi penting dalam mendukung keberlanjutan sistem pertanian dan pangan dengan memberikan informasi tentang perkembangan produksi tanaman sayuran untuk membantu petani, produsen, dan pemerintah merencanakan kegiatan pertanian dengan lebih efektif.

Kata kunci: JST, Produksi, Tanaman Sayuran, Gizi Masyarakat, Resilient

1. PENDAHULUAN

Tanaman sayuran memiliki peran penting dalam pemenuhan kebutuhan gizi masyarakat. Sayuran merupakan sumber alami dari berbagai vitamin dan mineral yang diperlukan oleh tubuh [1]. Misalnya, bayam kaya akan zat besi dan vitamin K, sedangkan wortel kaya akan vitamin A [2]. Sayuran juga mengandung serat makanan yang baik. Serat membantu pencernaan, mencegah sembelit, dan dapat

mengurangi risiko penyakit tertentu seperti penyakit jantung dan diabetes tipe dua [3]. Sebagian besar sayuran memiliki kandungan kalori yang rendah tetapi memberikan rasa kenyang. Ini membuatnya menjadi pilihan yang baik untuk mereka yang ingin menurunkan berat badan atau menjaga berat badan ideal [4]. Banyak sayuran kaya akan antioksidan yang membantu melindungi tubuh dari radikal bebas. Radikal bebas dapat menyebabkan kerusakan sel dan berkontribusi pada penuaan dini dan penyakit kronis. Konsumsi sayuran secara rutin telah dikaitkan dengan penurunan risiko penyakit kronis seperti penyakit jantung, stroke, dan beberapa jenis kanker [5]. Pada banyak negara, termasuk Indonesia, pertanian sayuran menjadi sumber pendapatan bagi banyak keluarga petani. Oleh karena itu, konsumsi sayuran lokal tidak hanya mendukung kesehatan tetapi juga ekonomi lokal. Oleh karena itu, upaya peningkatan produksi tanaman sayuran harus terus dilakukan meski upaya yang harus dilakukan semakin berat dan kompleks. Pada penelitian ini, produksi tanaman sayuran berfokus di Sumatera Utara yang merupakan Provinsi terbesar keempat di Indonesia.

Peningkatan produksi tanaman sayuran di Sumatera Utara (Sumut) merupakan langkah penting untuk memenuhi kebutuhan pangan penduduk setempat dan berkontribusi pada ketersediaan pasokan pangan di seluruh Indonesia. Sumut memiliki potensi pertanian yang cukup besar, baik dari segi lahan yang luas maupun kondisi iklim yang mendukung. Berdasarkan data Badan Pusat Statistik, dalam beberapa tahun terakhir yakni tahun 2021-2022, ada beberapa tanaman sayur di provinsi Sumatera Utara yang tren nya semakin menurun, seperti: Bawang Putih, Kentang, Kembang Kol, Petsai/Sawi, Kacang Panjang, Tomat, Buncis, Kangkung dan Bayam [6]. Sehingga dibutuhkan langkah-langkah strategis agar produksi tanaman sayur di Sumatera Utara jangan sampai menurun, salah satu nya adalah dengan melakukan analisa dan prediksi perkembangan produksi tanaman sayur untuk tahun-tahun selanjutnya, sebagai informasi dan masukkan bagi para pemangku kepentingan, khususnya Pemerintah provinsi Sumatera Utara agar dapat menentukan kebijakan sedini mungkin, dengan menerapkan langkah-langkah yang dianggap tepat dalam mempertahankan kestabilan produksi tanaman sayur.

Teknologi dan ilmu pengetahuan telah berkembang pesat, memberikan peluang untuk mengembangkan metode prediksi yang lebih canggih dan akurat. Salah satu teknologi yang saat ini sedang berkembang dan menunjukkan potensi besar dalam bidang prediksi adalah Jaringan Syaraf Tiruan (JST). JST mampu memodelkan dan memprediksi pola-pola kompleks dengan akurasi yang tinggi. Penelitian ini akan mengusulkan algoritma *Resilient* sebagai salah satu metode dalam JST untuk prediksi perkembangan produksi tanaman sayuran. Algoritma *Resilient* dikenal memiliki kemampuan adaptasi yang baik terhadap perubahan data dan mampu memberikan hasil prediksi yang akurat, dengan demikian diharapkan melalui penelitian ini, dapat ditemukan model prediksi yang efektif untuk perkembangan produksi tanaman sayuran, sehingga dapat mendukung upaya pemenuhan gizi masyarakat.

Penelitian terdahulu yang berhubungan dengan penelitian yang akan dilakukan antara lain: (Solikhun & Rahayu, 2022) menggunakan algoritma

Resilient untuk memprediksi Ekspor Minyak Bumi Mentah di Indonesia dengan menggunakan 5 model arsitektur, model 5-9-1 memiliki tingkat akurasi 43%, 5-10-1 memiliki tingkat akurasi 71%, 5-11-1=56%, 5-12-1=86%, dan 5-13-1 sebesar 71%. Model 5-12-1 terpilih sebagai model terbaik, karena tingkat akurasi yang lebih tinggi dengan MSE sebesar 0,034787 [7]. (Nurhayati et al., 2022) melakukan prediksi Potensi Produksi Bawang Merah di Indonesia menggunakan algoritma *Resilient*. Penelitian ini akan menggunakan empat model arsitektur, yakni: 6-5-1, 6-10-1, 6-17-1 dan 6-29-1. Berdasarkan analisis diperoleh hasil bahwa model 6-17-1 merupakan model terbaik, karena memiliki nilai Mean Square Error (MSE) pengujian yang lebih rendah dibandingkan tiga model yang lain, yaitu sebesar 0,0337792 dan tingkat akurasi yang cukup baik sebesar 79% dengan tingkat error yang digunakan 0,04 [8]. (Saputra et al., 2019) Memprediksi Pengangguran Terbuka di Indonesia Menurut Pendidikan Tertinggi yang Ditamatkan juga menggunakan algoritma *Resilient*. Penelitian menggunakan arsitektur 12-6-2, 12-12-2, 12-18-2, 12-24-2, 12-12-12-2, 12-12-18-2, 12-18-18-2 dan 12-18-24-2. Berdasarkan 8 model ini setelah dilakukan pelatihan dan pengujian diperoleh hasil bahwa model terbaik adalah 12-18-2, dengan Tingkat akurasi 75% [9]. Sedangkan penelitian yang diusulkan nanti nya akan memiliki akurasi yang lebih tinggi atau MSE yang lebih kecil dibandingkan penelitian-penelitian tersebut.

Berdasarkan latar belakang tersebut, maka dilakukan penelitian ini dengan tujuan melakukan prediksi produksi tanaman sayuran di Sumatera Utara berdasarkan model peramalan terbaik melalui serangkaian uji coba menggunakan Algoritma *Resilient*. Hasil dari penelitian diharapkan dapat dijadikan sebagai bahan pertimbangan khususnya bagi Pemerintah Provinsi Sumatera Utara dalam mengevaluasi kebijakan terkait target produksi tanaman sayuran, sehingga target yang ingin dicapai dapat lebih realistik. Selain itu hasil penelitian dalam penelitian ini juga dapat menjadi acuan untuk penelitian lain dengan topik yang sama.

2. METODOLOGI PENELITIAN

2.1. Pengumpulan Data

Pengumpulan data dilakukan dengan menggunakan teknik web scraping, yakni proses pengambilan data dari sebuah website. Dataset yang digunakan pada penelitian ini adalah data kuantitatif produksi tanaman sayur di Sumatera Utara 10 tahun terakhir (Tahun 2013-2022), yang diperoleh dari website Badan Pusat Statistik Indonesia. Tanaman sayuran masuk dalam kategori tanaman hortikultura, yang pengumpulan data nya dilakukan oleh Kepala Cabang Dinas (KCD)/Mantri Tani/Petugas Pengumpul Data Dinas Pertanian Kabupaten/Kota dengan metode perkiraan pengamatan lapang. Pengumpulan data menggunakan daftar register kecamatan dan daftar isian Survei Pertanian Hortikultura (SPH). Pengumpulan data menjadi tanggung jawab Dinas Pertanian Kabupaten/Kota. Pemeriksaan kelengkapan dan kebenaran isian dokumen SPH dilakukan oleh Dinas Pertanian Kabupaten/Kota. Hasilnya diserahkan kepada BPS Kabupaten/Kota untuk diolah. Validasi data dilakukan dalam forum sinkronisasi hasil pengolahan dan pencatatan baik di tingkat provinsi maupun pusat. Mulai tahun 2021 untuk tanaman Lobak

dan tanaman Kacang Merah tidak di publikasikan lagi. Data penelitian yang digunakan pada penelitian ini dapat dilihat pada Tabel 1 berikut.

Tabel 1. Data Produksi Tanaman Sayuran di Sumatera Utara (Ton)

NamaSayuran	Tahun					
	2013	...	2019	2020	2021	2022
Bawang Merah	8.305,00	...	18.072,00	29.222,00	53.962,00	64.835,00
Bawang Putih	109,00	...	975,00	1.339,00	805,00	21,00
Bawang Daun	12.822,00	...	13.259,00	13.615,00	15.632,00	18.052,00
Kentang	100.736,00	...	118.778,00	124.326,00	159.014,00	148.872,00
Kubis	165.589,00	...	219.537,00	201.966,00	233.761,00	236.611,00
Kembang Kol	28.764,00	...	53.278,00	57.739,00	59.100,00	57.340,00
Petsai / Sawi	69.820,00	...	78.728,00	75.424,00	74.908,00	74.370,00
Wortel	37.275,00	...	95.821,00	99.306,00	141.446,00	151.970,00
Kacang Panjang	40.653,00	...	29.313,00	32.189,00	28.386,00	26.333,00
Cabai Besar	161.933,00	...	154.008,00	193.862,00	210.220,00	211.747,00
Cabai Rawit	36.945,00	...	49.246,00	61.160,00	78.663,00	87.012,00
Tomat	114.168,00	...	118.583,00	162.744,00	203.162,00	183.015,00
Terung	67.259,00	...	60.244,00	60.244,00	51.320,00	57.114,00
Buncis	36.482,00	...	28.674,00	36.597,00	49.856,00	46.858,00
Ketimun	34.225,00	...	22.430,00	24.628,00	22.975,00	25.030,00
Labu Siam	20.797,00	...	21.243,00	11.203,00	14.047,00	16.321,00
Kangkung	22.094,00	...	13.652,00	16.996,00	23.071,00	23.002,00
Bayam	13.462,00	...	16.610,00	12.786,00	17.980,00	16.797,00
Melinju	5.117,00	...	2.615,00	4.483,00	4.878,00	5.271,00

Source: Badan Pusat Statistik Indonesia [6]

2.2. Algoritma Resilient

Resilient merupakan hasil pengembangan dari algoritma *Backpropagation*. Perubahan bobot pada *Backpropagation* dipengaruhi oleh learning rate dan tergantung dari kemiringan kurva eror ($\partial E / \partial W_{ij}$). Semakin kecil learning rate yang digunakan, maka pembelajaran akan lebih lama. Sementara semakin besar tingkat pembelajaran, nilai pembobotan akan jauh dari bobot minimum. Untuk mengatasinya, dikembangkan metode baru yaitu RProp (*Resilient Backpropagation*). Metode ini menggunakan tanda (positif atau negatif) dari gradien untuk menunjukkan arah penyesuaian bobot. Sementara ukuran perubahan bobotnya adalah ditentukan oleh penyesuaian nilai (Δ_0) [10]. Metode *Resilient* mengubah bobot dan jaringan bias dengan proses adaptasi langsung dari pembobotan berdasarkan informasi gradien lokal dari iterasi pembelajaran, sehingga jumlah iterasi diperlukan mencapai target [11].

Secara umum cara kerja metode *Resilient Backpropagation* (RProp) dapat diterangkan sebagai berikut [12]:

1) Inisialisasi Penyesuaian Awal $\Delta_{ij}(t) = \Delta_0 = 0$, Gradient Awal $\partial E / \partial W_{ij} . (t-1) = 0$ (1)

2) Lakukan langkah-langkah berikut sampai bobot konvergen

a. Hitung Gradient $\partial E / \partial W.t$ (2)

b. Untuk semua bobot, hitung nilai penyesuaian.

1. Jika $\partial E / \partial W.t * \partial E / \partial W_{ij} . (t-1) \geq 0$ maka

$$\Delta_{ij}(t) = \min(\Delta_{ij}(t - 1) * \eta^+, \Delta_{max}) \quad (3)$$

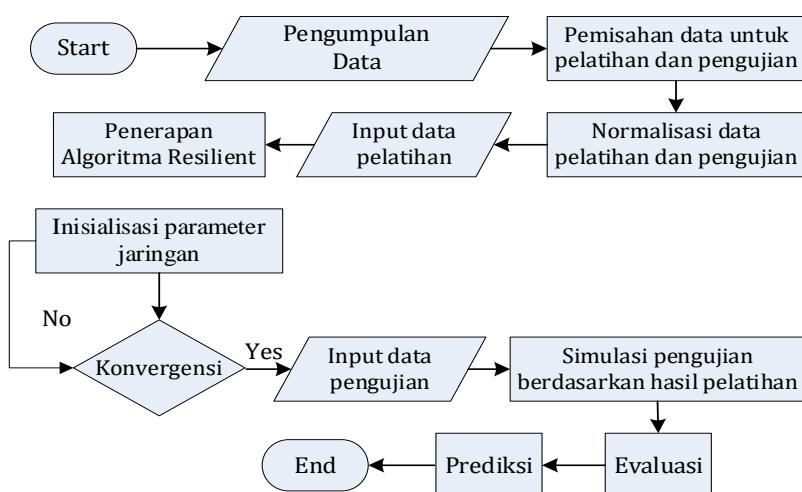
2. Jika $\partial E / \partial W(t) * \partial E / \partial W_{ij} . (t-1) < 0$ maka

$$\Delta_{ij}(t) = \max(\Delta_{ij}(t-1) * \eta^-, \Delta_{\min}) \quad (4)$$
- c. Hitung perubahan bobot
 1. Jika $\partial E / \partial W(t) > 0$ maka

$$w(t+1) = w(t) - \Delta_{ij}(t) \quad (5)$$
 2. Jika $\partial E / \partial W(t) < 0$ maka

$$w(t+1) = w(t) + \Delta_{ij}(t) \quad (6)$$
 3. Selesai.

2.3. Flowchart Penelitian



Gambar 1. Flowchart Penelitian

Gambar 1 merupakan *Flowchart* penelitian untuk menyelesaikan masalah Prediksi Produksi Tanaman Sayuran di Sumatera Utara Tahun 2023 dengan Algoritma *Resilient*. Hal pertama yang dilakukan pada tahapan penelitian adalah dengan mengumpulkan dataset penelitian (Berdasarkan tabel 1). Langkah berikutnya memisahkan dataset penelitian menjadi 2 bagian, yakni untuk data pelatihan dan pengujian. Tahapan berikutnya melakukan normalisasi data pelatihan dan pengujian dengan menggunakan rumus persamaan (2) [13]–[18].

$$x' = \frac{0,8(x-b)}{(a-b)} + 0,1 \quad (7)$$

Keterangan :

- x' : Data Transformasi
- x : Data yang akan di normalisasi
- a : Data paling kecil dari dataset
- b : Data paling besar dari dataset
- 0.1 / 0.8 : Nilai default Normalisasi

Selanjutnya data pelatihan yang sudah di normalisasi dimasukkan kedalam aplikasi Matlab 2011b untuk di proses, dilanjutkan dengan membuat jaringan saraf multi layer (input data pelatihan). Selanjutnya penerapan machine learning

dengan teknik *Resilient*. Pembuatan jaringan saraf multi layer ini menggunakan fungsi *tansig* dan *logsig*. Tahapan selanjutnya adalah dilakukan inisialisasi parameter jaringan berdasarkan fungsi pelatihan yang digunakan (trainrp). Kemudian memasukkan perintah untuk dilakukan proses pelatihan dan melihat hasil saat performance ditemukan. Apabila hasil pelatihan mencapai konvergensi, maka akan dilanjutkan memasukkan data pengujian yang sudah di normalisasi. Tetapi jika hasil pelatihan belum mencapai konvergensi, maka kembali ke tahap inisialisasi parameter jaringan. Tahapan berikutnya dilanjutkan dengan simulasi data uji berdasarkan hasil pelatihan. Apabila semua sudah dilakukan, tahapan selanjutnya adalah melakukan evaluasi untuk melihat model arsitektur terbaik berdasarkan tingkat akurasi terbaik. Tahapan akhir melakukan prediksi jumlah Produksi Tanaman Sayuran di Sumatera Utara Tahun 2023.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Normalisasi

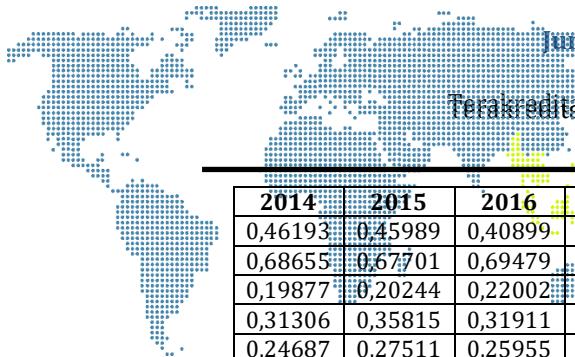
Berdasarkan tabel 1, data akan dibagi menjadi dua bagian (data pelatihan dan data pengujian). Data pelatihan menggunakan data tahun 2013-2020 sebagai input dan data tahun 2021 sebagai target (output). Sedangkan untuk data pengujian menggunakan data tahun 2014-2021 sebagai input dan data tahun 2022 sebagai target (output). Langkah selanjutnya melakukan normalisasi menggunakan rumus persamaan (7) yang sudah dibahas sebelumnya. Hasil normalisasi dapat dilihat pada tabel 2 dan tabel 3 berikut.

Tabel 2. Normalisasi Data Training

2013	2014	2015	2016	2017	2018	2019	2020	Target (2021)
0,12830	0,12660	0,13400	0,14563	0,15499	0,15579	0,16173	0,19989	0,28457
0,10024	0,10000	0,10031	0,10011	0,10006	0,10007	0,10321	0,10445	0,10263
0,14376	0,13935	0,13851	0,13536	0,13256	0,13746	0,14525	0,14647	0,15338
0,44467	0,46631	0,46424	0,41272	0,43152	0,46959	0,50643	0,52542	0,64415
0,66666	0,69369	0,68403	0,70203	0,71725	0,69145	0,85131	0,79117	0,90000
0,19832	0,19993	0,20364	0,22144	0,23559	0,23735	0,28223	0,29750	0,30216
0,33885	0,31562	0,36126	0,32174	0,33981	0,31493	0,36934	0,35804	0,35627
0,22746	0,24861	0,27720	0,26145	0,27409	0,29242	0,42785	0,43978	0,58402
0,23902	0,25152	0,25422	0,23825	0,25029	0,20977	0,20020	0,21005	0,19703
0,65414	0,60581	0,74280	0,62230	0,64455	0,63327	0,62702	0,76343	0,81942
0,22633	0,21589	0,23561	0,20187	0,20847	0,23619	0,26843	0,30921	0,36912
0,49065	0,38855	0,49231	0,44176	0,43311	0,45465	0,50576	0,65692	0,79526
0,33009	0,31308	0,33661	0,36547	0,38337	0,33866	0,30608	0,30608	0,27553
0,22474	0,21474	0,20222	0,17374	0,20062	0,18487	0,19802	0,22514	0,27052
0,21702	0,22298	0,22876	0,20302	0,20467	0,19416	0,17664	0,18417	0,17851
0,17106	0,16937	0,19078	0,14645	0,13809	0,15275	0,17258	0,13822	0,14795
0,17549	0,17577	0,18806	0,15508	0,15639	0,15153	0,14660	0,15804	0,17884
0,14595	0,15724	0,16795	0,17149	0,16982	0,16916	0,15672	0,14363	0,16141
0,11738	0,11143	0,10905	0,10826	0,10768	0,10884	0,10882	0,11521	0,11657

Tabel 3. Normalisasi Data Testing

2014	2015	2016	2017	2018	2019	2020	2021	Target (2022)
0,12634	0,13364	0,14513	0,15438	0,15517	0,16104	0,19874	0,28239	0,31916
0,10006	0,10037	0,10017	0,10012	0,10013	0,10323	0,10446	0,10265	0,10000
0,13893	0,13810	0,13499	0,13222	0,13706	0,14476	0,14597	0,15279	0,16097



2014	2015	2016	2017	2018	2019	2020	2021	Target (2022)
0,46193	0,45989	0,40899	0,42756	0,46517	0,50156	0,52032	0,63762	0,60332
0,68655	0,67701	0,69479	0,70983	0,68434	0,84227	0,78285	0,89036	0,90000
0,19877	0,20244	0,22002	0,23401	0,23574	0,28008	0,29517	0,29977	0,29382
0,31306	0,35815	0,31911	0,33696	0,31238	0,36614	0,35497	0,35322	0,35140
0,24687	0,27511	0,25955	0,27204	0,29014	0,42394	0,43572	0,57821	0,61380
0,24974	0,25241	0,23663	0,24853	0,20849	0,19905	0,20877	0,19591	0,18897
0,59974	0,73507	0,61603	0,63801	0,62687	0,62069	0,75545	0,81076	0,81593
0,21454	0,23402	0,20070	0,20721	0,23459	0,26645	0,30673	0,36592	0,39415
0,38511	0,48761	0,43767	0,42913	0,45041	0,50090	0,65023	0,78690	0,71877
0,31056	0,33380	0,36231	0,37999	0,33583	0,30364	0,30364	0,27346	0,29305
0,21341	0,20104	0,17291	0,19946	0,18390	0,19689	0,22368	0,26851	0,25837
0,22154	0,22726	0,20183	0,20346	0,19308	0,17577	0,18321	0,17762	0,18456
0,16859	0,18974	0,14594	0,13768	0,15216	0,17176	0,13781	0,14743	0,15512
0,17491	0,18705	0,15447	0,15577	0,15096	0,14609	0,15740	0,17794	0,17771
0,15660	0,16719	0,17068	0,16903	0,16838	0,15609	0,14316	0,16073	0,15673
0,11135	0,10900	0,10822	0,10765	0,10879	0,10877	0,11509	0,11642	0,11775

3.2. Analisis Model

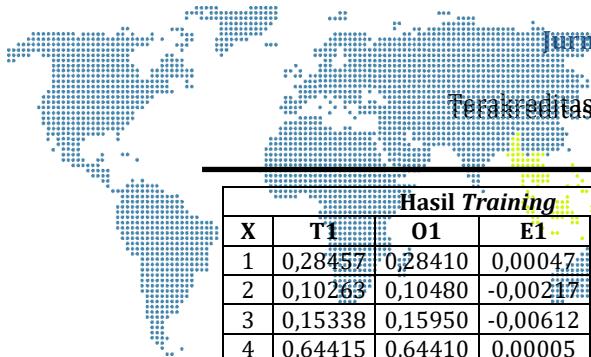
Tidak ada pedoman yang tetap dalam algoritma Jaringan Saraf Tiruan mengenai cara menentukan model arsitektur yang tepat. Semua harus mencoba dan mencoba, berarti terus mencoba model sampai menemukan atau mendapatkan model terbaik. Pada penelitian ini, ada lima model arsitektur jaringan akan dianalisis, yaitu 8-8-1, 8-16-1, 8-24-2, 8-32-1 dan 8-40-1. Setiap model ini akan dilatih dan diuji menggunakan Matlab2011b.

Tabel 4. Hasil Training dan Testing dengan Model 8-8-1

Hasil Training					Hasil Testing				
X	T1	O1	E1	SSE1	T2	O2	E2	SSE2	H
1	0,28457	0,28620	-0,00163	0,00000264	0,31916	0,33620	-0,01704	0,00029034	1
2	0,10263	0,10670	-0,00407	0,00001660	0,10000	0,10550	-0,00550	0,00003025	1
3	0,15338	0,16140	-0,00802	0,00006438	0,16097	0,17840	-0,01743	0,00030382	1
4	0,64415	0,64450	-0,00035	0,00000012	0,60332	0,71900	-0,11568	0,01338155	1
5	0,90000	0,90010	-0,00010	0,00000001	0,90000	0,91530	-0,01530	0,00023409	1
6	0,30216	0,30300	-0,00084	0,00000070	0,29382	0,33960	-0,04578	0,00209607	1
7	0,35627	0,35660	-0,00033	0,00000011	0,35140	0,42700	-0,07560	0,00571506	1
8	0,58402	0,58370	0,00032	0,00000010	0,61380	0,90720	-0,29340	0,08608540	1
9	0,19703	0,19770	-0,00067	0,00000045	0,18897	0,17000	0,01897	0,00035989	0
10	0,81942	0,81930	0,00012	0,00000002	0,81593	0,86190	-0,04597	0,00211366	1
11	0,36912	0,37010	-0,00098	0,00000096	0,39415	0,36760	0,02655	0,00070487	0
12	0,79526	0,79490	0,00036	0,00000013	0,71877	0,70360	0,01517	0,00023018	0
13	0,27553	0,27490	0,00063	0,00000040	0,29305	0,23370	0,05935	0,00352277	0
14	0,27052	0,26500	0,00552	0,00003047	0,25837	0,32540	-0,06703	0,00449254	1
15	0,17851	0,18740	-0,00889	0,00007903	0,18456	0,13950	0,04506	0,00203084	0
16	0,14795	0,14910	-0,00115	0,00000132	0,15512	0,12140	0,03372	0,00113680	0
17	0,17884	0,16860	0,01024	0,00010483	0,17771	0,17340	0,00431	0,00001855	1
18	0,16141	0,15280	0,00861	0,00007418	0,15673	0,17070	-0,01397	0,00019527	1
19	0,11657	0,11570	0,00087	0,00000075	0,11775	0,11730	0,00045	0,00000020	1
			JSSE	0,00037721			JSSE	0,12294217	68%
			MSE	0,00001985			MSE	0,00647064	

Tabel 5. Hasil Training dan Testing pada Model 8-16-1

Hasil Training					Hasil Testing				
X	T1	O1	E1	SSE1	T2	O2	E2	SSE2	H



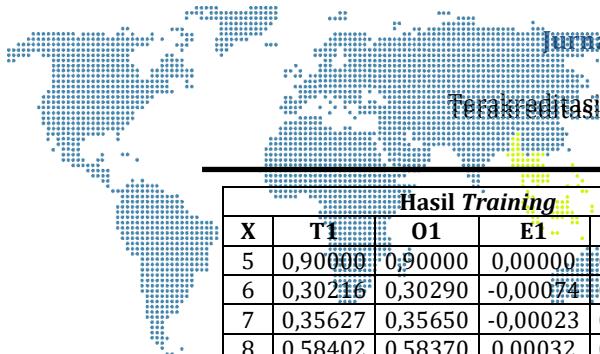
X	T1	Hasil Training			Hasil Testing					H
		O1	E1	SSE1	T2	O2	E2	SSE2	H	
1	0,28457	0,28410	0,00047	0,00000022	0,31916	0,50950	-0,19034	0,03622910	1	
2	0,10263	0,10480	-0,00217	0,00000473	0,10000	0,10150	-0,00150	0,00000225	1	
3	0,15338	0,15950	-0,00612	0,00003750	0,16097	0,16740	-0,00643	0,00004135	1	
4	0,64415	0,64410	0,00005	0,00000000	0,60332	0,68710	-0,08378	0,00701886	1	
5	0,90000	0,89990	0,00010	0,00000001	0,90000	0,86680	0,03320	0,00110224	0	
6	0,30216	0,30270	-0,00054	0,00000029	0,29382	0,25620	0,03762	0,00141505	0	
7	0,35627	0,35660	-0,00033	0,00000011	0,35140	0,28920	0,06220	0,00386909	0	
8	0,58402	0,58400	0,00002	0,00000000	0,61380	0,64210	-0,02830	0,00080107	1	
9	0,19703	0,19470	0,00233	0,00000543	0,18897	0,15810	0,03087	0,00095301	0	
10	0,81942	0,81950	-0,00008	0,00000001	0,81593	0,81490	0,00103	0,00000105	1	
11	0,36912	0,36910	0,00002	0,00000000	0,39415	0,41280	-0,01865	0,00034785	1	
12	0,79526	0,79530	-0,00004	0,00000000	0,71877	0,85240	-0,13363	0,01785652	1	
13	0,27553	0,27530	0,00023	0,00000005	0,29305	0,24160	0,05145	0,00264741	0	
14	0,27052	0,26830	0,00222	0,00000493	0,25837	0,32600	-0,06763	0,00457334	1	
15	0,17851	0,18490	-0,00639	0,00004083	0,18456	0,16810	0,01646	0,00027109	0	
16	0,14795	0,14560	0,00235	0,00000553	0,15512	0,12110	0,03402	0,00115712	0	
17	0,17884	0,17810	0,00074	0,00000055	0,17771	0,19580	-0,01809	0,00032734	1	
18	0,16141	0,15870	0,00271	0,00000736	0,15673	0,18590	-0,02917	0,00085112	1	
19	0,11657	0,11210	0,00447	0,00001995	0,11775	0,11850	-0,00075	0,00000056	1	
			JSSE	0,00012751			JSSE	0,07946540		
			MSE	0,00000671			MSE	0,00418239		63%

Tabel 6. Hasil Training dan Testing pada Model 4-24-1

X	T1	Hasil Training			Hasil Testing					H
		O1	E1	SSE1	T2	O2	E2	SSE2	H	
1	0,28457	0,28490	-0,00033	0,00000011	0,31916	0,43550	-0,11634	0,01353486	1	
2	0,10263	0,10610	-0,00347	0,00001207	0,10000	0,10420	-0,00420	0,00001764	1	
3	0,15338	0,15870	-0,00532	0,00002834	0,16097	0,17010	-0,00913	0,00008336	1	
4	0,64415	0,64420	-0,00005	0,00000000	0,60332	0,73960	-0,13628	0,01857187	1	
5	0,90000	0,90000	0,00000	0,00000000	0,90000	0,90470	-0,00470	0,00002209	1	
6	0,30216	0,30280	-0,00064	0,00000041	0,29382	0,29940	-0,00558	0,00003117	1	
7	0,35627	0,35650	-0,00023	0,00000005	0,35140	0,35430	-0,00290	0,00000840	1	
8	0,58402	0,58380	0,00022	0,00000005	0,61380	0,75600	-0,14220	0,02022173	1	
9	0,19703	0,19500	0,00203	0,00000413	0,18897	0,17960	0,00937	0,00008781	1	
10	0,81942	0,81940	0,00002	0,00000000	0,81593	0,84330	-0,02737	0,00074937	1	
11	0,36912	0,36910	0,00002	0,00000000	0,39415	0,37790	0,01625	0,00026404	0	
12	0,79526	0,79530	-0,00004	0,00000000	0,71877	0,89610	-0,17733	0,03144532	1	
13	0,27553	0,27540	0,00013	0,00000002	0,29305	0,25340	0,03965	0,00157236	0	
14	0,27052	0,26870	0,00182	0,00000331	0,25837	0,34960	-0,09123	0,00832226	1	
15	0,17851	0,18470	-0,00619	0,00003832	0,18456	0,16880	0,01576	0,00024853	0	
16	0,14795	0,14770	0,00025	0,00000006	0,15512	0,12750	0,02762	0,00076267	0	
17	0,17884	0,17450	0,00434	0,00001882	0,17771	0,19780	-0,02009	0,00040371	1	
18	0,16141	0,15820	0,00321	0,00001032	0,15673	0,18480	-0,02807	0,00078815	1	
19	0,11657	0,11260	0,00397	0,00001573	0,11775	0,11750	0,00025	0,00000006	1	
			JSSE	0,00013175			JSSE	0,09713541		
			MSE	0,00000693			MSE	0,00511239		79%

Tabel 7. Hasil Training dan Testing pada Model 4-32-1

X	T1	Hasil Training			Hasil Testing					H
		O1	E1	SSE1	T2	O2	E2	SSE2	H	
1	0,28457	0,28420	0,00037	0,00000014	0,31916	0,46820	-0,14904	0,02221275	1	
2	0,10263	0,10420	-0,00157	0,00000248	0,10000	0,10330	-0,00330	0,00001089	1	
3	0,15338	0,15760	-0,00422	0,00001784	0,16097	0,17470	-0,01373	0,00018852	1	
4	0,64415	0,64420	-0,00005	0,00000000	0,60332	0,73280	-0,12948	0,01676472	1	



X	T1	Hasil Training			Hasil Testing					H
		O1	E1	SSE1	T2	O2	E2	SSE2	H	
5	0,90000	0,90000	0,00000	0,000000000	0,90000	0,91010	-0,01010	0,00010201	1	
6	0,30216	0,30290	-0,00074	0,00000055	0,29382	0,30540	-0,01158	0,00013416	1	
7	0,35627	0,35650	-0,00023	0,00000005	0,35140	0,48790	-0,13650	0,01863170	1	
8	0,58402	0,58370	0,00032	0,00000010	0,61380	0,80130	-0,18750	0,03515743	1	
9	0,19703	0,19580	0,00123	0,00000152	0,18897	0,15680	0,03217	0,00103496	0	
10	0,81942	0,81940	0,00002	0,00000000	0,81593	0,88720	-0,07127	0,00508006	1	
11	0,36912	0,36930	-0,00018	0,00000003	0,39415	0,41490	-0,02075	0,00043059	1	
12	0,79526	0,79520	0,00006	0,00000000	0,71877	0,92010	-0,20133	0,04053308	1	
13	0,27553	0,27550	0,00003	0,00000000	0,29305	0,33350	-0,04045	0,00163596	1	
14	0,27052	0,26930	0,00122	0,00000149	0,25837	0,29920	-0,04083	0,00166680	1	
15	0,17851	0,18130	-0,00279	0,00000778	0,18456	0,16680	0,01776	0,00031559	0	
16	0,14795	0,14730	0,00065	0,00000042	0,15512	0,20110	-0,04598	0,00211449	1	
17	0,17884	0,17880	0,00004	0,00000000	0,17771	0,23840	-0,06069	0,00368359	1	
18	0,16141	0,15910	0,00231	0,00000535	0,15673	0,19410	-0,03737	0,00139682	1	
19	0,11657	0,11320	0,00337	0,00001133	0,11775	0,11550	0,00225	0,00000507	1	
			JSSE	0,00004910				JSSE	0,15109919	
			MSE	0,00000258				MSE	0,00795259	89%

Tabel 8. Hasil *Training* dan *Testing* pada Model 4-40-1

X	T1	Hasil Training			Hasil Testing					H
		O1	E1	SSE1	T2	O2	E2	SSE2	H	
1	0,28457	0,28430	0,00027	0,00000008	0,31916	0,39200	-0,07284	0,00530558	1	
2	0,10263	0,10590	-0,00327	0,00001072	0,10000	0,10330	-0,00330	0,00001089	1	
3	0,15338	0,15740	-0,00402	0,00001619	0,16097	0,17210	-0,01113	0,00012389	1	
4	0,64415	0,64420	-0,00005	0,00000000	0,60332	0,66950	-0,06618	0,00437961	1	
5	0,90000	0,90000	0,00000	0,00000000	0,90000	0,93850	-0,03850	0,00148225	1	
6	0,30216	0,30240	-0,00024	0,00000006	0,29382	0,29930	-0,00548	0,00003006	1	
7	0,35627	0,35650	-0,00023	0,00000005	0,35140	0,34980	0,00160	0,00000257	1	
8	0,58402	0,58390	0,00012	0,00000001	0,61380	0,73350	-0,11970	0,01432884	1	
9	0,19703	0,19610	0,00093	0,00000087	0,18897	0,15450	0,03447	0,00118824	0	
10	0,81942	0,81940	0,00002	0,00000000	0,81593	0,92660	-0,11067	0,01224886	1	
11	0,36912	0,36920	-0,00008	0,00000001	0,39415	0,38510	0,00905	0,00008189	1	
12	0,79526	0,79520	0,00006	0,00000000	0,71877	0,91420	-0,19543	0,03819221	1	
13	0,27553	0,27560	-0,00007	0,00000000	0,29305	0,28480	0,00825	0,00006811	1	
14	0,27052	0,26940	0,00112	0,00000125	0,25837	0,28810	-0,02973	0,00088366	1	
15	0,17851	0,18080	-0,00229	0,00000524	0,18456	0,15150	0,03306	0,00109328	0	
16	0,14795	0,14700	0,00095	0,00000090	0,15512	0,13510	0,02002	0,00040066	0	
17	0,17884	0,17890	-0,00006	0,00000000	0,17771	0,20070	-0,02299	0,00052866	1	
18	0,16141	0,15970	0,00171	0,00000293	0,15673	0,18760	-0,03087	0,00095321	1	
19	0,11657	0,11140	0,00517	0,00002669	0,11775	0,11810	-0,00035	0,00000012	1	
			JSSE	0,00006503				JSSE	0,08130259	
			MSE	0,00000342				MSE	0,00427908	84%

Keterangan:

- X = Data Tanaman Sayuran
- T1 & T2 = Target *Training* dan Target *Testing*
- O1 & O2 = Output (Keluaran) *Training* dan *Testing*
- E1 & E2 = Error (Kesalahan) *Training* dan *Testing*
- SSE1 & SSE2 = Sum Square Error
- JSSE = Jumlah SSE
- MSE = Mean Square Error
- H = Hasil Akurasi

Berdasarkan hasil *training* dan hasil *testing* pada Tabel 4, Tabel 5, Tabel 6, Tabel 7, dan Tabel 8, dapat dijelaskan sebagai berikut :

T1 & T2 = Didapatkan dari normalisasi berdasarkan persamaan (2), menggunakan *Microsoft Excel*

O1 dan O2 = Didapatkan dari perhitungan dengan menggunakan Matlab2011b.

E1 dan E2 = Didapatkan dari perhitungan Target - *Output*

SSE1 & SSE2 = Didapatkan dari perhitungan *Error* pangkat 2.

JSSE = Diperoleh dari Total seluruh SSE

MSE = Didapatkan dari jumlah SSE dibagi dengan 10 (banyaknya dataset)

H = 1 (*true*) dan 0 (*false*). 1 (satu) didapatkan jika nilai *Error* $\leq 0,01$.

Selain itu akan bernilai 0 (nol). 0,01 merupakan target *Error* yang digunakan pada penelitian ini.

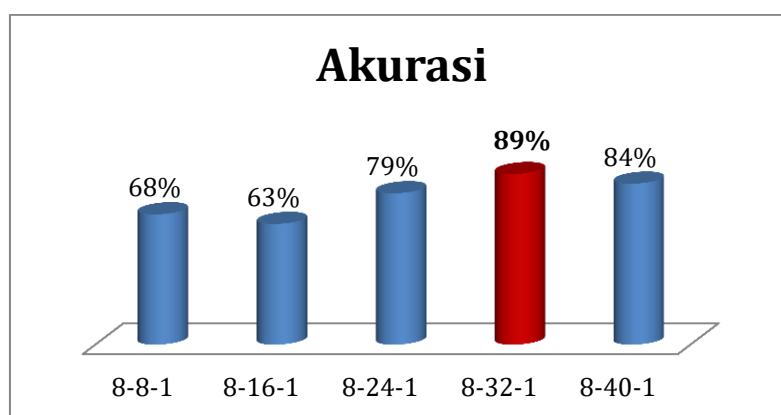
3.3. Pemilihan Model Terbaik

Berdasarkan penyajian hasil pelatihan dan pengujian pada Tabel 4, Tabel 5, Tabel 6, Tabel 7, dan Tabel 8 yang merupakan hasil perhitungan dari masing-masing model arsitektur jaringan yang digunakan pada penelitian ini, maka selanjutnya dapat ditentukan model terbaik dari masing-masing model yang digunakan. Perbandingan tersebut dapat dilihat pada Tabel 9 berikut ini.

Tabel 9. Perbandingan Model Arsitektur

No	Arsitektur	Data Training				Data Testing	
		Epoch	Waktu	MSE	Fungsi	MSE	Akurasi
1	8-8-1	6538	00.18	0,00001985	<i>tansig, logsig</i>	0,00647064	68%
2	8-16-1	4931	00.13	0,00000671		0,00418239	63%
3	8-24-1	4136	00.11	0,00000693		0,00511239	79%
4	8-32-1	3273	00.09	0,00000258		0,00795259	89%
5	8-40-1	2786	00.07	0,00000342		0,00427908	84%

Tabel 9 merupakan perbandingan dari masing-masing model arsitektur yang digunakan pada penelitian ini. Secara garis besar model arsitektur 8-32-1 merupakan model arsitektur terbaik, karena memiliki tingkat akurasi 89%.



Gambar 2. Grafik Perbandingan Akurasi

Gambar 2 merupakan grafik dari hasil model arsitektur yang digunakan. 5 (Lima) model yang digunakan pada penelitian ini cukup berbeda jauh hasil akurasi nya, antara lain 68%, 63%, 79%, 89% dan 84%. Model 8-32-1 merupakan model terbaik dengan akurasi 89% (tertinggi dibandingkan model yang lain).

3.4. Prediksi Produksi Tanaman Sayuran

Prediksi diperoleh dan diproses berdasarkan model arsitektur terbaik, yakni model 7-15-1 dengan menggunakan rumus persamaan (3) [19]–[21].

$$\text{Prediksi} = \frac{(x-0,1)(b-a)}{0,8} + a \quad (8)$$

Penjelasan :

- x = Target Prediksi
- a = Data Nilai Terendah
- b = Data Nilai Tertinggi
- 0.1 dan 0.8 = Nilai default untuk Proses Prediksi

Tabel 10. Perbandingan Produksi Tanaman Sayuran dan Hasil Prediksi

No	Provinsi	Produksi Sebelumnya (Ton)					Prediksi
		2018	2019	2020	2021	2022	
1	Bawang Merah	16.337	18.072	29.222	53.962	64.835	64.699
2	Bawang Putih	59	975	1.339	805	21	908
3	Bawang Daun	10.982	13.259	13.615	15.632	18.052	17.706
4	Kentang	108.016	118.778	124.326	159.014	148.872	148.866
5	Kubis	172.833	219.537	201.966	233.761	236.611	236.611
6	Kembang Kol	40.165	53.278	57.739	59.100	57.340	57.394
7	Petsai / Sawi	62.831	78.728	75.424	74.908	74.370	74.340
8	Wortel	56.254	95.821	99.306	141.446	151.970	151.971
9	Kacang Panjang	32.107	29.313	32.189	28.386	26.333	26.637
10	Cabai Besar	155.836	154.008	193.862	210.220	211.747	211.769
11	Cabai Rawit	39.825	49.246	61.160	78.663	87.012	86.997
12	Tomat	103.650	118.583	162.744	203.162	183.015	183.023
13	Terung	69.764	60.244	60.244	51.320	57.114	57.157
14	Buncis	24.832	28.674	36.597	49.856	46.858	46.925
15	Ketimun	27.547	22.430	24.628	22.975	25.030	24.212
16	Labu Siam	15.448	21.243	11.203	14.047	16.321	16.168
17	Kangkung	15.092	13.652	16.996	23.071	23.002	23.887
18	Bayam	20.244	16.610	12.786	17.980	16.797	16.996
19	Melinju	2.621	2.615	4.483	4.878	5.271	4.457
Jumlah		974.443	1.115.066	1.219.829	1.443.186	1.450.571	1.450.725

Berdasarkan tabel 10 dapat dilihat perbandingan antara produksi tanaman sayuran di Sumatera Utara di tahun-tahun sebelumnya, yakni tahun 2018 hingga tahun 2022 dan berdasarkan hasil prediksi tahun 2023. Terlihat bahwa perkembangan produksi tanaman sayuran secara keseluruhan meningkat, khususnya pada 3 tahun terakhir, yakni tahun 2021 hingga tahun 2022 dan berdasarkan hasil prediksi tahun 2023. Tetapi secara spesifik berdasarkan hasil

prediksi di tahun 2023, ada beberapa jenis sayuran yang kemungkinan akan mengalami penurunan produksi, seperti: bawang merah, bawang daun, kentang, petisai/sawi, cabai rawit, ketimun, labu siam, dan melinju. Walaupun penurunan produksi tanaman sayuran tersebut tidak terlalu signifikan.

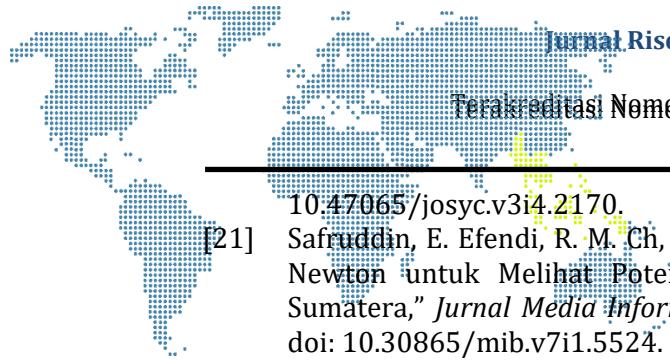
4. SIMPULAN

Kesimpulan utama yang dapat diambil dari penelitian ini adalah bahwa algoritma *Resilient* memiliki potensi untuk menjadi alat yang berguna dalam meramalkan perkembangan produksi tanaman sayuran, dengan mengintegrasikan algoritma ini ke dalam proses perencanaan pertanian, para petani dan pemangku kepentingan terkait dapat lebih siap menghadapi perubahan yang mungkin terjadi. Selain itu, hasil prediksi yang lebih akurat juga dapat membantu dalam mengoptimalkan strategi distribusi dan pemasaran produk pertanian, sehingga kontribusi terhadap pemenuhan gizi masyarakat menjadi lebih signifikan. Namun, penting untuk diingat bahwa prediksi dalam pertanian memiliki tingkat ketidakpastian yang inheren. Faktor-faktor seperti kondisi cuaca yang tak terduga, serangan hama, dan perubahan pasar dapat mempengaruhi hasil produksi. Oleh karena itu, meskipun algoritma *Resilient* dapat memberikan panduan berharga, keputusan akhir harus tetap didasarkan pada kombinasi informasi dari berbagai sumber dan pertimbangan yang komprehensif. Secara keseluruhan, penelitian ini membuka pintu bagi penggunaan teknologi algoritma dalam mendukung keberlanjutan pertanian dan pemenuhan gizi masyarakat, dengan terus mengembangkan model dan memperkaya dataset, penelitian mendatang dapat lebih lanjut meningkatkan akurasi prediksi dan dampak positifnya terhadap kesejahteraan masyarakat.

DAFTAR PUSTAKA

- [1] E. Djuwendah, T. Karyani, Z. Saidah, and O. Hasbiansyah, "Pelatihan Budidaya Sayuran Secara Vertikultur di Pekarangan Guna Ketahanan Pangan Rumah Tangga," *Dinamisia: Jurnal Pengabdian Kepada Masyarakat*, vol. 5, no. 2, pp. 349–355, 2021, doi: 10.31849/dinamisia.v5i2.5291.
- [2] F. D. Rahmayanti, "Sosialisasi Potensi Sumberdaya Hayati Untuk Konsumsi Pangan Sehat," *Jurnal Pelita Pengabdian*, vol. 1, no. 2, pp. 254–259, 2023.
- [3] N. Cholifah and Sokhiatun, "Pengaruh Diet Tinggi Serat Terhadap Tekanan Darah Pada Penderita Hipertensi," *Jurnal Ilmu Keperawatan dan Kebidanan*, vol. 13, no. 2, pp. 412–420, 2022.
- [4] M. R. Suari and I. Samsul, "Perlindungan Konsumen Terhadap Informasi Diet Dalam Buku Program Diet Yang Ditulis Oleh Bukan Ahli Gizi," *Jurnal Education and Development*, vol. 11, no. 1, pp. 212–220, 2022, doi: 10.37081/ed.v11i1.4314.
- [5] W. Hanifah, W. S. Oktavia, and H. Nisa, "Faktor Gaya Hidup Dan Penyakit Jantung Koroner: Review Sistematik Pada Orang Dewasa Di Indonesia," *Penelitian Gizi dan Makanan (The Journal of Nutrition and Food Research)*, vol. 44, no. 1, pp. 45–58, 2021, doi: 10.22435/pgm.v44i1.4187.
- [6] BPS, "Produksi Tanaman Sayuran," *Publikasi Statistik Indonesia*, 2023. <https://www.bps.go.id/indicator/55/61/1/produksi-tanaman-sayuran.html>
- [7] S. Solikhun and I. Rahayu, "Prediksi Ekspor Minyak Bumi Mentah di Indonesia dengan Algoritma Resilient Backpropagation," *BRAHMANA: Jurnal Penerapan*

- Kecerdasan Buatan, vol. 4, no. 1, pp. 115–121, 2022, [Online]. Available: <https://www.pkm.tunasbangsa.ac.id/index.php/brahmana/article/view/157%0Ah> <https://www.pkm.tunasbangsa.ac.id/index.php/brahmana/article/viewFile/157/156>
- [8] Nurhayati, M. B. Sibuea, D. Kusbiantoro, M. Silaban, and A. Wanto, "Implementasi Algoritma Resilient untuk Prediksi Potensi Produksi Bawang Merah di Indonesia," *Building of Informatics, Technology and Science (BITS)*, vol. 4, no. 2, pp. 1051–1060, 2022, doi: 10.47065/bits.v4i2.2269.
- [9] W. Saputra, J. T. Hardinata, and A. Wanto, "Implementation of Resilient Methods to Predict Open Unemployment in Indonesia According to Higher Education Completed," *JITE (Journal of Informatics and Telecommunication Engineering)*, vol. 3, no. 1, pp. 163–174, 2019, doi: 10.31289/jite.v3i1.2704.
- [10] M. Riedmiller and H. Braun, "RPROP - A Fast Adaptive Learning Algorithm," *The International Symposium on Computer and Information Science VII*, vol. 1, no. 4, pp. 4–10, 1992, doi: 10.1007/978-1-4419-1603-7_12.
- [11] W. Saputra, T. Tulus, M. Zarlis, R. W. Sembiring, and D. Hartama, "Analysis Resilient Algorithm on Artificial Neural Network Backpropagation," *Journal of Physics: Conference Series*, vol. 930, no. 1, pp. 1–7, 2017, doi: 10.1088/1742-6596/930/1/012035.
- [12] Apriliyah and A. W. W. M, Wayan Firdaus, "Perkiraan Penjualan Beban Listrik Menggunakan Jaringan Syaraf Tiruan Resilient Backpropogation (RPROP)," *Jurnal Kursor*, vol. 4, no. 2, pp. 41–47, 2008, doi: 10.1089/fpd.2015.2079.
- [13] P. Parulian *et al.*, "Analysis of Sequential Order Incremental Methods in Predicting the Number of Victims Affected by Disasters," *Journal of Physics: Conference Series*, vol. 1255, no. 012033, pp. 1–6, 2019, doi: 10.1088/1742-6596/1255/1/012033.
- [14] I. M. Muhamad, S. A. Wardana, A. Wanto, and A. P. Windarto, "Algoritma Machine Learning untuk penentuan Model Prediksi Produksi Telur Ayam Petelur di Sumatera," vol. 1, no. 4, pp. 126–134, 2022.
- [15] E. Siregar, H. Mawengkang, E. B. Nababan, and A. Wanto, "Analysis of Backpropagation Method with Sigmoid Bipolar and Linear Function in Prediction of Population Growth," *Journal of Physics: Conference Series*, vol. 1255, no. 012023, pp. 1–6, 2019, doi: 10.1088/1742-6596/1255/1/012023.
- [16] R. Sinaga, M. M. Sitomorang, D. Setiawan, A. Wanto, and A. P. Windarto, "Akurasi Algoritma Fletcher-Reeves untuk Prediksi Ekspor Karet Remah Berdasarkan Negara Tujuan Utama," *Journal of Informatics Management and Information Technology*, vol. 2, no. 3, pp. 91–99, 2022, doi: 10.47065/jimat.v2i3.170.
- [17] Y. Andriani, H. Silitonga, and A. Wanto, "Analisis Jaringan Syaraf Tiruan untuk prediksi volume ekspor dan impor migas di Indonesia," *Register - Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 4, no. 1, pp. 30–40, 2018.
- [18] M. Mahendra, R. C. Telaumbanua, A. Wanto, and A. P. Windarto, "Akurasi Prediksi Ekspor Tanaman Obat , Aromatik dan Rempah-Rempah Menggunakan Machine Learning," *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 2, no. 6, pp. 207–215, 2022.
- [19] S. Setti and A. Wanto, "Analysis of Backpropagation Algorithm in Predicting the Most Number of Internet Users in the World," *JOIN (Jurnal Online Informatika)*, vol. 3, no. 2, pp. 110–115, 2018, doi: 10.15575/join.
- [20] S. Aisyah, Z. Zulkifli, and P. A. Cakranegara, "Penerapan Algoritma Bayesian Regulation untuk Estimasi Posisi Cadangan Devisa Indonesia," *Journal of Computer System and Informatics (JoSYC)*, vol. 3, no. 4, pp. 205–211, 2022, doi:



-
- [21] 10.47065/josyc.v3i4.2170.
Safruddin, E. Efendi, R. M. Ch, and A. Wanto, "Pemanfaatan Algoritma BFGS Quasi-Newton untuk Melihat Potensi Perkembangan Luas Tanaman Kopi di Pulau Sumatera," *Jurnal Media Informatika Budidarma*, vol. 7, no. 1, pp. 473–483, 2023, doi: 10.30865/mib.v7i1.5524.