



Prediksi Cuaca Berdasarkan Variasi miliVolt Xylem *Lannea coromandelica* Menggunakan Model Artificial Neural Network Backpropagation

Iskandar ^{1*}, Stella Elizabeth Warokka ¹

¹ Program Studi Sistem Informasi, Universitas Pohuwato, Indonesia

* Korespondensi: iskardartech919@gmail.com

Situs: Iskandar, I.; Warokka, S. E. (2025). Prediksi Cuaca Berdasarkan Variasi miliVolt Xylem *Lannea coromandelica* Menggunakan Model Artificial Neural Network Backpropagation. *JTIM: Jurnal Teknologi Informasi dan Multimedia*, 7(3), 616-625. <https://doi.org/10.35746/jtim.v7i3.727>

Diterima: 17-04-2025

Direvisi: 02-07-2025

Disetujui: 09-07-2025



Copyright: © 2025 oleh para penulis. Karya ini dilisensikan di bawah Creative Commons Attribution-ShareAlike 4.0 International License. (<https://creativecommons.org/licenses/by-sa/4.0/>).

Abstract: The rate of fluid flow in tree xylem generates an electrical potential difference (mV), which serves as a physiological indicator for monitoring plant conditions and predicting weather. This study aimed to develop a regression model based on Artificial Neural Network Backpropagation (ANN-BP) to estimate weather parameters from mV data of *Lannea coromandelica*. Electrical potential data were collected continuously for seven days using xylem-mounted sensors and synchronized with actual weather data, including air temperature, relative humidity, and light intensity. ANN-BP models employing three training algorithms (*traingdx*, *traincgb*, and *traingd*) were compared using mean squared error (MSE) as the evaluation metric. The *traincgb* algorithm achieved the best performance with an MSE of 3.29×10^{-4} . These findings demonstrate that variations in xylem electrical potential can reliably predict weather conditions in real time, supporting the development of an energy-efficient, biologically based weather monitoring system for precision agriculture and climate change mitigation.

Keywords: Artificial Neural Network, Backpropagation, mV Xylem, Prediksi Cuaca, *Lannea coromandelica*

Abstrak: Laju aliran cairan dalam jaringan *xylem* pohon menghasilkan perbedaan potensial listrik (mV) yang dapat dimanfaatkan sebagai indikator fisiologis untuk memantau kondisi tanaman sekaligus memprediksi cuaca. Penelitian ini bertujuan mengembangkan model regresi berbasis Artificial Neural Network Backpropagation (ANN-BP) untuk memprediksi parameter cuaca dari data mV *xylem* pohon *Lannea coromandelica*. Data mV dikumpulkan selama tujuh hari menggunakan sensor yang terpasang pada *xylem*, kemudian dipadankan dengan data cuaca aktual yang meliputi suhu udara, kelembaban relatif, dan intensitas cahaya. Model ANN-BP dibangun dengan beberapa fungsi pelatihan (*traingdx*, *traincgb*, dan *traingd*) untuk membandingkan performa prediksi. Evaluasi dilakukan menggunakan *mean squared error* (MSE). Hasil menunjukkan bahwa model ANN-BP dengan fungsi pelatihan *traincgb* memberikan akurasi terbaik dengan nilai MSE sebesar 0.00032917. Temuan ini menunjukkan bahwa variasi potensial listrik pada *xylem* dapat menjadi prediktor yang andal untuk memperkirakan kondisi cuaca secara *real-time*. Pendekatan ini berpotensi dikembangkan sebagai sistem pemantauan cuaca hemat energi berbasis indikator biologis, yang relevan untuk pertanian presisi dan mitigasi perubahan iklim.

Kata kunci: Artificial Neural Network, Backpropagation, mV Xylem, Prediksi Cuaca, *Lannea coromandelica*.

1. Pendahuluan

Cuaca merupakan salah satu faktor lingkungan yang sangat berpengaruh terhadap fisiologi tanaman, termasuk proses fotosintesis, pengangkutan unsur hara, pembentukan glukosa, dan metabolisme sekunder seperti resin [1]. Variabilitas cuaca yang semakin tinggi akibat perubahan iklim global dapat mengganggu produktivitas tanaman dan ketepatan jadwal budidaya [2]. Oleh karena itu, diperlukan metode pemantauan dan prediksi cuaca yang akurat serta hemat energi, terutama bagi sektor pertanian presisi. Pohon *Lannea coromandelica* memiliki jaringan xylem dengan potensial listrik (millivolt), yang dapat dimanfaatkan sebagai indikator fisiologis untuk memantau kondisi tanaman [3]. Potensi listrik (millivolt) pada jaringan xylem, adalah respon tanaman terhadap perubahan lingkungan khususnya perubahan cuaca [4].

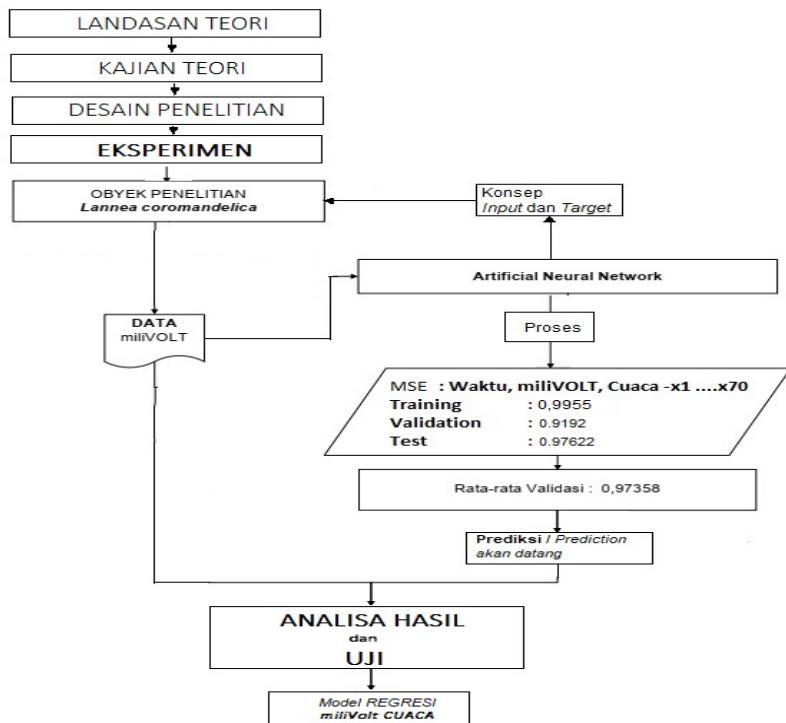
Berbagai penelitian terdahulu telah menunjukkan bahwa potensi listrik pada xylem dipengaruhi oleh dinamika aliran air, kondisi tanah, serta faktor meteorologi seperti suhu, kelembaban, dan curah hujan [5],[6]. Metode komputasi berbasis *Artificial Neural Network* (ANN) telah banyak digunakan dalam pemodelan hubungan kompleks antara variabel lingkungan dan respons biologis tanaman, karena kemampuannya menangani data non-linear dan multivariat [7]. Beberapa studi telah menerapkan ANN untuk prediksi cuaca maupun deteksi kondisi fisiologis tanaman [8], namun pemanfaatan data *millivolt* xylem secara langsung sebagai variabel prediktor masih relatif jarang dieksplorasi.

Celah penelitian (*research gap*) yang muncul adalah minimnya kajian yang mengintegrasikan data fisiologis tanaman, khususnya variasi *millivolt* xylem, dengan model prediksi cuaca berbasis ANN yang membandingkan performa berbagai fungsi pelatihan (*training functions*) secara sistematis. Selain itu, belum banyak studi yang memfokuskan pada tanaman *Lannea coromandelica* sebagai objek penelitian, padahal spesies ini memiliki potensi fisiologis yang responsif terhadap perubahan cuaca.

Penelitian ini bertujuan untuk mengembangkan model prediksi cuaca berbasis ANN-Backpropagation menggunakan data *millivolt* xylem pohon *Lannea coromandelica* dengan membandingkan tiga fungsi pelatihan, yaitu *Gradient Descent Backpropagation* (*traingd*), *Gradient Descent with Adaptive Learning Rate and Momentum* (*traingdx*), dan *Conjugate Gradient Backpropagation with Powell–Beale Restarts* (*traincgb*) [9][10]. Kontribusi penelitian ini terletak pada penyajian analisis komparatif performa fungsi pelatihan ANN dalam memodelkan hubungan fisiologis–meteorologis, serta memberikan rekomendasi metode yang paling akurat dan efisien untuk diaplikasikan pada sistem pemantauan cuaca berbasis sensor biologis.

2. Bahan dan Metode

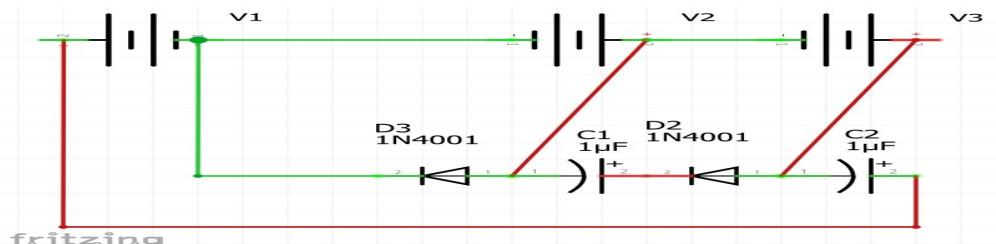
Untuk mengembangkan model prediksi cuaca berdasarkan variasi mV xylem pada pohon *lennea coromandelica* digunakan metode eksperimen untuk mendapatkan model prediksi dengan fungsi pelatihan yang paling akurat. Oleh karena itu terdapat se rangkaian tahapan penelitian yang harus dilakukan seperti yang tersaji pada Gambar 1 dibawah ini.



Gambar 1. Diagram Tahapan Penelitian

2.1. Pengumpulan Data

Data yang digunakan pada penelitian ini adalah data primer yang diperoleh dari rangkaian elektronik yang terpasang pada batang pohon *Lannea coromandelica*. Proses pengumpulan data dari perangkat elektornik tersebut dilakukan dalam tujuh hari, dengan mencatat variasi mV xylem mulai pukul 07.30 sampai dengan 19.00, serta kondisi cuaca aktual. Rangkaian alat elektronik yang digunakan untuk mencatat variasi nilai mV xylem pada pohon tersaji pada Gambar 2 dibawah ini



Gambar 2. Rangkaian Alat Pencatat millivolt xylem pohon *Lannea coromandelica*

Alat elektronik ini akan merekam potensi listrik (*millivolt*) pada jaringan xylem pohon *Lannea coromandelica* secara real-time [11]. Alat ini diinstalasi pada batang pohon yang berukuran besar dengan menancapkan kutub positif pada satu sisi batang pohon dan menancapkan kutub negatif ke ujung batang pohon [12],[13]. Kemudian kedua kutub tersebut disambungkan dengan perangkat display yang menampilkan potensi listrik (*millivolt*) [14]. Dari pemasangan perangkat ini kemudian dikumpulkan selama tujuh hari, dimana data tersebut terdiri dari tiga kolom, yaitu kolom tanggal pengamatan, kolom jam pengamatan, dan kolom besaran potensi listrik (*millivolt*). Sementara data cuaca dilakukan dengan pengamatan secara manual. Sehingga menghasilkan data seperti pada Tabel 1. di bawah ini.

Tabel 1. Data hasil pengamatan mV xylem pohon *lennea coromandelica* dalam tujuh hari

Tanggal Pengamatan	Jam ke	millivolt (mV)	Cuaca
12/08/2024	07.30	0.237	Berawan
	07.32	0.247	Berawan
	07.39	0.24	Berawan

	19.00	0.262	Tak Berawan

13/08/2024	07.30	0.23	Tak Berawan
	07.41	0.29	Tak Berawan
	08.51	0.289	Tak Berawan

15/08/2024	19.00	0.256	Dingin
	07.30	0.26	Berawan
	07.32	0.269	Berawan
	07.39	0.265	Berawan

16/08/2024	19.00	0.247	Berawan
	07.30	0.27	Cerah
	07.53	0.288	Cerah
	08.10	0.277	Cerah
17/08/2024
	19.00	0.235	Dingin
	07.30	0.28	Tak Berawan
	07.53	0.288	Tak Berawan
	08.10	0.277	Tak Berawan
21/08/2024
	19.00	0.254	Mendung
	07.30	0.275	Tak Berawan
	07.32	0.275	Tak Berawan
	07.37	0.278	Tak Berawan
03/09/2024
	19.00	0.214	Mendung
	07.30	0.206	Mendung
	07.35	0.207	Mendung
	07.39	0.200	Mendung
19.00
	19.00	0.212	Mendung

Sebelum pelatihan model ANN-BP, dilakukan pemeriksaan awal terhadap variabel-variabel dataset yang telah dikumpulkan untuk memastikan data lengkap, konsisten, dan relevan [15].

2.2. Pre-Processing

Tahap awal sebelum pelatihan *model Backpropagation (BP)* adalah melakukan pemeriksaan dan analisis awal terhadap variabel-variabel pada dataset. Langkah ini bertujuan untuk memastikan bahwa seluruh data yang digunakan memiliki kelengkapan, konsistensi, serta relevansi terhadap permasalahan penelitian. Pemeriksaan meliputi deteksi data hilang (missing values), identifikasi outlier, kesesuaian tipe data, dan validasi rentang nilai setiap variabel. Dengan demikian, dataset yang digunakan pada tahap pelatihan telah memenuhi kualitas yang diperlukan untuk menghasilkan model prediksi yang optimal.

Kemudian dataset akan dibagi menjadi dua bagian, yaitu data *training*, dan data *testing*. Data *training* akan digunakan sebagai data latih untuk model mengenali pola, sembari data *testing* akan digunakan untuk mengukur kemampuan generalisasi model pada

data yang belum pernah dilihat. Metode pembagian dataset yang digunakan adalah metode *Hold-out* dimana dataset akan dibagi dengan proporsi 80% sebagai data *training* dan 20% sebagai data *testing* [16].

2.3. Artificial Neural Network Backpropagation

Artificial Neural Network (ANN) merupakan model komputasi yang cara kerjanya meniru cara kerja otak manusia. ANN dirancang untuk meniru struktur dan fungsi sel saraf biologis, dengan tujuan untuk memproses informasi dan belajar dari data [17]. Pada arsitektur ANN terdapat tiga lapisan yaitu lapisan input (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan output (*output layer*) [18]. ANN bekerja dengan dua tahap besar, yaitu mengalirkan data dari input hingga output disebut *forward propagation*, dan yang kedua dengan menghitung error dan memperbaiki bobot agar prediksi lebih akurat disebut *backward propagation* [19]. Kedua tahap utama ini dilengkapi dengan fungsi aktivasi yang memiliki peranan penting dalam pembentukan lapisan luaran maupun dalam perhitungan gradien selema proses pembelajaran.

1. Tahap Forward Propagation

Pada tahap ini, data masukkan dikalikan dengan bobot w dan dijumlahkan dengan bias, seperti persamaan berikut ini :

$$z_j^{(l)} = \sum_{i=1}^{n^{(l-1)}} w_j^{(l)} \cdot a_i^{(l-1)} + b_j^{(l)}$$

Nilai $z_j^{(l)}$ kemudian dilewatkan ke fungsi aktivasi untuk menghasilkan keluaran neuron. Fungsi aktivasi ini dapat menggunakan fungsi sigmoid, Tanh, atau ReLU.

2. Perhitungan Loss

Setelah diperoleh luaran neuron, dilakukan perhitungan error atau fungsi kerugian [9]. Dimana untuk regresi menggunakan Mean Squared Error (MSE), dengan persamaan sebagai berikut :

$$E = \frac{1}{2} \sum_{k=1}^{n^{(L)}} (y_k - a_k^{(L)})^2$$

Dengan y_k adalah target sebenarnya, dan $a_k^{(L)}$ adalah keluaran prediksi jaringan.

3. Tahap Backpropagation

Tahap ini bertujuan menghitung gradien terhadap bobot dan bias, yang digunakan untuk memperbarui parameter. Kesalahan pada lapisan keluaran dihitung sebagai:

$$\delta_k^{(L)} = (a_k^{(L)} - y_k) \cdot \varphi'(z_k^{(L)})$$

Dan juga kesalahan pada lapisan tersembunyi dihitung secara rekursif:

$$\delta_j^{(L)} = \left(\sum_{k=1}^{n^{(l+1)}} w_{kj}^{(l+1)} \cdot \delta_k^{(l+1)} \right) \cdot \varphi'(z_j^{(l)})$$

4. Pembaruan Bobot dan Bias

Selanjutnya dilakukan pembaruan terhadap nilai bobot dan bias dengan menggunakan gradien descent dengan persamaan berikut :

$$w_{ij}^{baru} = w_{ij}^{lama} + \eta \cdot \delta_j \cdot a_i$$

$$b_{ij}^{baru} = b_{ij}^{lama} + \eta \cdot \delta_j$$

Dimana η adalah learning rate, dan a_i adalah output dari neuron sebelumnya, serta δ_j adalah error term neuron ke - j.

Dalam MATLAB tersedia beberapa fungsi pelatihan yang berbasis pada *gradient descent*, namun ditambahkan teknik lainnya untuk mempercepat kovergensi atau mencegah *overfitting*. Pada penelitian ini digunakan tiga fungsi pelatihan yang disediakan pada MATLAB, yaitu *Gradient Descent Backpropagation*, *Gradient Descent with Adaptive Learning Rate and Momentum*, dan *Conjugate Gradient Backpropagation with Powell-Beale Restarts* [20]. Tujuannya untuk mengoptimasi kinerja model dan membandingkan performa model prediksi yang dikembangkan.

2.3.1. ANN-BP Gradient Descent Backpropagation

Fungsi ini dalam MATLAB disebut sebagai *traingd*, yang menggunakan gradient descent murni, dimana cara kerjanya bobot langsung diperbarui dengan menggunakan turunan dari fungsi error seperti MSE [20]. Fungsi ini cukup mudah dipahami dan sangat sederhana untuk diimplementasi. Untuk memperbarui bobot berikut persamaannya :

$$w_{baru} = w_{lama} - \eta \cdot \frac{\partial E}{\partial w}$$

Dimana η adalah learning rate, dan E adalah fungsi error (MSE), dan $\frac{\partial E}{\partial w}$ adalah turunan parsial error terhadap bobot

2.3.2. ANN-BP Gradient Descent with Adaptive Learning Rate and Momentum

Fungsi pelatihan ini menggabungkan tiga elemen penting, yaitu gradient descent sebagai pembaruan bobot mengikuti arah *gradient negative* dan fungsi error, momentum untuk mempercepat kovergensi dengan mempertahankan sebagian "arah gerak" sebelumnya agar tidak terjebak di *local minima*, dan *adaptive learning rate*, dimana nilai learning rate akan datur secara dinamis selama pelatihan. Nilai learning rate akan meningkat jika pembaruan error memperbaiki error, dan akan menurun jika memperburuk error [16][20]. Dalam MATLAB fungsi ini dikenal sebagai *traingx*. Berikut adalah persamaannya dalam memperbarui bobot pada setiap iterasi:

$$\begin{aligned}\Delta w(t) &= \alpha(t) \cdot \frac{\partial E}{\partial w} + \mu \cdot \Delta w(t-1) \\ w(t+1) &= w(t) - \Delta w(t)\end{aligned}$$

Dimana $\alpha(t)$ adalah learning rate adaptif pada iterasi ke-t, μ adalah faktor momentum $[0,1]$, $\frac{\partial E}{\partial w}$ adalah gradien error terhadap bobot, dan $\Delta w(t-1)$ adalah perubahan bobot pada iterasi sebelumnya.

2.3.3. Conjugate Gradient Backpropagation with Powell-Beale Restarts

Fungsi pelatihan ini dalam MATLAB dikenal sebagai *traincgb*, dan bekerja dengan mencari arah pencarian bobot yang lebih efisien daripada sekedar mengikuti gradien negatif pada setiap iterasi. Kelebihan utamanya adalah kecepatan karena tidak memerlukan penentuan learning rate yang sangat kecil. Selain itu fungsi ini bekerja lebih baik pada dataset besar dan permasalahan dengan error surface yang kompleks [20].

2.4. Pengukuran Kinerja Model

Untuk memastikan hasil prediksi cuaca mendekati data aktual, maka dilakukan proses pengukuran kinerja model ANN-BP [20]. Proses pengukuran fokus untuk menghitung rata-rata selisih antara output dari hasil prediksi model dengan target aktual [x]. Pengukuran kinerja model prediksi ini berdasarkan pada nilai Mean Square Error (MSE).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Dimana y_i adalah nilai target sebenarnya, \hat{y}_i adalah nilai prediksi model, dan n adalah jumlah sample data. Pengukuran kinerja model menggunakan MSE dilakukan pada setiap fungsi pelatihan ANN-BP yaitu *traingd*, *traingdx*, dan *traincgb*. Kemudian nilai MSE antar fungsi pelatihan tersebut dibandingkan, dimana nilai MSE yang lebih kecil memiliki hasil prediksi model pada dataset testing yang mendekati targetnya, atau dengan kata lain merupakan hasil prediksi yang paling akurat.

3. Hasil

Bagian ini dapat dibagi dengan *subheading*. Ini harus memberikan deskripsi singkat dan tepat tentang hasil eksperimen, interpretasinya, serta kesimpulan eksperimen yang dapat ditarik.

3.1. Pre-Processing

Pada tahap ini dilakukan dua hal yaitu melakukan normalisasi terhadap dataset agar berada pada rentang [0,1], dan yang kedua adalah mengubah variable bertipe data string menjadi numerik. Hasil dari tahap pre-processing ini tersaji pada Tabel 2 dibawah ini:

Tabel 2. Hasil Proses Pre-Processing

Tanggal Pengamatan	millivolt (mV)	Cuaca
12/08/2024	0.237	0.3290494
	0.247	0.3290494

03/09/2024	0.212	0.270436

Dataset yang sudah dinormalisasi ini, kemudian bagi menjadi dua bagian 80% dataset akan digunakan dalam proses pelatihan atau disebut sebagai data training. Sisanya yaitu 20% dataset digunakan untuk proses testing, atau disebut sebagai data testing.

3.2. Performa ANN-BP Pada Data Training

Tabel 3. Perbandingan Performa ANN-BP Pada Setiap Fungsi Pelatihan Dari Data Training

MSE		
Traingd	Traingdx	Traincgb
0.0060629	0.0019417	2.7043e-05

Terlihat pada Tabel 3 model ANN-BP yang menggunakan fungsi pelatihan *traincgb* memiliki nilai MSE yang paling rendah jika dibandingkan dengan lainnya. Hal ini menunjukkan kesesuaiannya untuk prediksi cuaca. Hasil ini masih terbatas pada data training saja, dimana model memang sudah mengenali data ini sebelumnya. Oleh karena itu perlu untuk diuji bagaimana keakuratan model dalam memprediksi data yang belum dikenalinya.

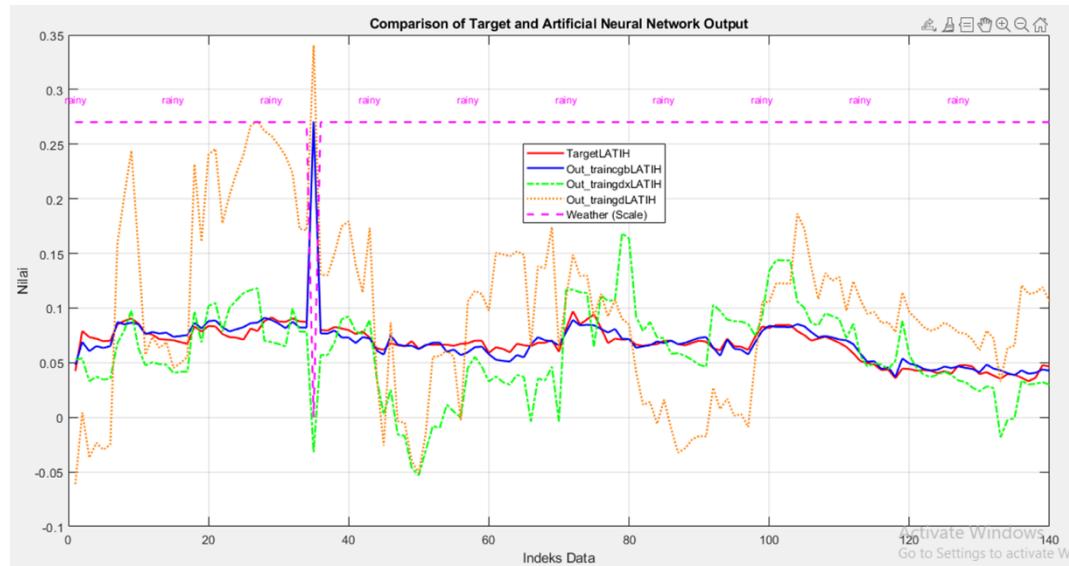
3.3. Performa ANN-BP Pada Data Testing

Tabel 4. Perbandingan Performa ANN-BP Pada Setiap Fungsi Pelatihan Dari Data Testing

MSE		
Traingd	Traingdx	Traincgb
0.011036	0.027455	0.00032917

Selanjutnya prediksi dilakukan menggunakan data testing. Hasil performa model ANN-BP pada tiap fungsi pelatihan tersaji pada Tabel 4. Terlihat bahwa model ANN-BP dengan fungsi pelatihan Conjugate Gradient Backpropagation with Powell–Beale Restarts atau *traincgb* memiliki performa yang lebih baik dengan nilai MSE yang paling kecil

sebesar 0.00032917. Hal ini sejalan dengan hasil performa yang ditunjukkan model saat menggunakan data training.



Gambar 3. Plot Perbandingan Kinerja Model Target Vs Model ANN

Oleh karena itu, seperti yang diilustrasikan pada Gambar 3, terlihat model ANN-BP dengan fungsi pelatihan *traincgb* paling baik dalam memprediksi data yang belum dikenalinya dibandingkan dengan model ANN-BP dengan fungsi pelatihan lainnya.

4. Pembahasan

Hasil penelitian menunjukkan bahwa fungsi pelatihan *Conjugate Gradient Backpropagation with Powell–Beale Restarts* (*traincgb*) memberikan kinerja terbaik pada data *training* dan *testing* dengan MSE masing-masing $2.7043e-05$ dan 0.00032917 , menandakan kemampuan model dalam mempelajari pola hubungan *millivolt* (mV) xylem dengan cuaca secara efektif dan mempertahankan akurasi pada data baru dikenali. Keunggulan ini disebabkan oleh efisiensi konvergensi *Conjugate Gradient* yang dipadukan dengan mekanisme *Powell–Beale Restarts*, yang mampu menghindari *local minima* dan mempercepat pelatihan dibandingkan *traingd* dan *traingdx* [20]. Perbedaan MSE yang kecil antara *training* dan *testing* menunjukkan tidak terjadinya *overfitting*, selaras dengan temuan literatur bahwa metode ini memiliki keseimbangan antara kecepatan pelatihan dan kemampuan generalisasi. Temuan ini konsisten dengan penelitian [21],[15] yang melaporkan bahwa algoritma *Conjugate Gradient* lebih unggul dalam akurasi dan stabilitas pada berbagai domain prediksi, termasuk data sensor lingkungan.

Secara praktis, *traincgb* direkomendasikan untuk prediksi cuaca berbasis data sensor lingkungan yang fluktuatif, meskipun uji lanjut dengan variasi dataset dan integrasi *feature selection* tetap diperlukan untuk meningkatkan *robustness* model. Temuan ini juga sejalan dengan penelitian sebelumnya, yang menyatakan bahwa adanya pengaruh cuaca dengan pertumbuhan tanaman, khususnya pada saat cuaca hujan dengan intensitas tinggi [22]. Hujan mempengaruhi pertumbuhan tunas, serta proses pengangkutan unsur hara dari akar ke daun, sebagai unsur penting untuk pembentukan glukosa, fotosintesis, serta resin [23]. Perubahan warna resin terjadi tiga kali lebih cepat pada cuaca hujan dibandingkan dengan cuaca tidak hujan [24].

5. Kesimpulan

Fungsi pelatihan *Conjugate Gradient Backpropagation with Powell–Beale Restarts* (*traincgb*) terbukti paling optimal dalam membangun model prediksi cuaca berbasis parameter

fisiologis (mV xylem) tanaman, dengan MSE sangat rendah pada data training dan testing, menunjukkan kemampuannya mempelajari pola hubungan millivolt–cuaca secara efektif dan mempertahankan akurasi pada data baru. Peluang penelitian selanjutnya meliputi perluasan cakupan dan variasi dataset, penerapan *feature selection* atau *dimensionality reduction* untuk efisiensi komputasi, serta pengembangan metode optimisasi guna meningkatkan performa dan *robustness* model terhadap data sensor yang bising.

Ucapan Terima Kasih: Penulis menyampaikan penghargaan dan terima kasih yang sebesar-besarnya kepada Universitas Pohuwato yang memberikan LOKASI Penelitian sebagai Universitas dari Yayasan Pengembangan Ilmu Pengetahuan dan Teknologi (YPIPT) Ichsan Gorontalo. Dukungan moral, motivasi, dan doa dari keluarga serta pihak-pihak lain yang tidak dapat disebutkan satu per satu turut menjadi bagian penting dalam terselesaikannya penelitian dan penulisan artikel ini

Referensi

- [1] I. Iskandar, "REPRESENTASI MILIVOLT PADA BATANG LANNEA COROMANDELICA MENGUKUR ADANYA LAJU GLUKOSA, AIR TANAH SAAT PERUBAHAN SUHU LINGKUNGAN," *Jurnal Locus Penelitian dan Pengabdian*, vol. 3, no. 1, pp. 1–21, 2024, <https://doi.org/10.58344/locus.v3i1.2414>.
- [2] M. M. S. Sitti, "Pemodelan Pengaruh Faktor Cuaca Terhadap Curah Hujan Ekstrem di Kota Makassar Pada 13 Februari 2023," 2024. <http://repository.unhas.ac.id:443/id/eprint/41941>
- [3] P. Prabhu, B. Karthikeyan, R. R. R. M. Vannan, and A. Balaji, "Mechanical, thermal and morphological analysis of hybrid natural and glass fiber-reinforced hybrid resin nanocomposites," *Biomass Convers Biorefin*, vol. 14, no. 4, pp. 4941–4955, 2024, <https://doi.org/10.1007/s13399-022-02632-9>.
- [4] J. N. Gunjal, M. S. Patil, and K. P. Chittam, "Lannea coromandelica: An overview," *International Journal of Pharmaceutical and Biological Science Archive*, vol. 9, no. 1, pp. 64–75, 2021, [<https://ijpba.in/index.php/ijpba/article/view/181>
- [5] M. Tarakeswara Naidu, D. Premavani, S. Suthari, and M. Venkaiah, "Assessment of tree diversity in tropical deciduous forests of Northcentral Eastern Ghats, India," *Geology, Ecology, and Landscapes*, vol. 2, no. 3, pp. 216–227, 2018, <https://doi.org/10.1080/24749508.2018.1452479>.
- [6] R. K. Chaturvedi and A. S. Raghubanshi, "Effect of soil moisture on composition and diversity of trees in tropical dry forest," *MOJ Ecology \& Environmental Sciences*, vol. 3, no. 1, pp. 1–4, 2018, <https://doi.org/10.15406/mojes.2018.03.00059>.
- [7] J. Balaji, "Artificial Neural Network, Theory and Application."
- [8] F. Marini, "Artificial Neural Networks (ANNs)," 2022.
- [9] B. Baliga, "Fundamental of Artificial Neural Network."
- [10] D. K. Pratihar, *Soft computing: fundamentals and applications*. Alpha Science International, Ltd, 2013. <https://dl.acm.org/doi/abs/10.5555/2566770>
- [11] F. Yuliantono, "Characteristics of Diode and Recessing (Karakteristik Dioda dan Penyearah)," 2021.
- [12] M. F. Aulia and A. Mulyadi, "Rangkaian Penyearah Gelombang Penuh Dengan Modifikasi IC Untuk Mengurangi Output Ripple Gelombang DC," *Energy: Jurnal Ilmiah Ilmu-Ilmu Teknik*, vol. 13, no. 2, pp. 131–140, 2023, <http://dx.doi.org/10.51747/energy.v13i2.1779>.
- [13] S. M. Siagian, G. W. Jaya, and I. Nurhidayati, "Analisis Jumlah Muatan Listrik Serta Energi Pada Kapasitor Berdasarkan Konstanta Dielektrik Suatu Material," *ORBITA: Jurnal Pendidikan dan Ilmu Fisika*, vol. 7, no. 1, pp. 176–180, 2021, <https://doi.org/10.31764/orbita.v7i1.4420>.
- [14] G. Anelli, "Introduction to Switched Capacitor Circuits," *ReCALL*, vol. 1, no. December, p. 47, 2003.
- [15] N. T. Luchia, E. Tasia, I. Ramadhan, A. Rahmadeyan, and R. Zahra, "Performance Comparison Between Artificial Neural Network, Recurrent Neural Network and Long Short-Term Memory for Prediction of Extreme Climate Change," *Public Research Journal of Engineering, Data Technology and Computer Science*, vol. 1, no. 2, pp. 62–70, 2024, <https://doi.org/10.57152/predatecs.v1i2.864>.
- [16] M. AZHIMA, "Penerapan Metode Backpropagation Neural Network untuk Klasifikasi Penyakit Stroke," *Penerapan Metode Backpropagation Neural Network untuk Klasifikasi Penyakit Stroke*, vol. 4, no. 6, pp. 3013–3021, 2024, <http://repository.uin-suska.ac.id/id/eprint/81776>.
- [17] 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, 2017, <https://doi.org/10.25077/TEKNOSI.v3i3.2017.370-380>.
- [18] D. Wungguli, B. P. Silalahi, and S. Guritman, "Metode steepest descent dengan ukuran langkah baru untuk pengoptimuman nirkendala," *MILANG Journal of Mathematics and Its Applications*, vol. 14, no. 1, pp. 1–10, 2015, <https://doi.org/10.29244/jmap.14.1.1-10>.

- [19] A. Wanto, "Prediksi Angka Partisipasi Sekolah dengan Fungsi Pelatihan Gradient Descent With Momentum & Adaptive LR," *Jurnal Ilmu Komputer dan Informatika (ALGORITMA)*, vol. 3, no. 1, pp. 9–20, 2019, <http://dx.doi.org/10.30829/algoritma.v3i1.4431>.
- [20] R. Ramadana, A. P. Windarto, and D. Suhendro, "Comparative Analysis of Gradient Descent Learning Algorithms in Artificial Neural Networks for Forecasting Indonesian Rice Prices," *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, vol. 8, no. 4, pp. 466–478, 2024, <https://doi.org/10.29207/resti.v8i4.5822>.
- [21] Z. M. M. Amin and S. A. K. Ali, "RETRACTED: Climate change prediction using artificial neural network," in *IOP Conference Series: Earth and Environmental Science*, 2022, p. 12003. <https://iopscience.iop.org/article/10.1088/1755-1315/961/1/012003/meta>
- [22] M. Masriana, M. Napitupulu, and S. T. Gonggo, "Pengaruh Konsentrasi Getah Pohon Kayu Jawa (*Lannea Coromandelica*) Terhadap Konduktivitas Membran Blend Kitosan-Polivinil Alkohol-Litium Sebagai Membran Elektrolit," *Jurnal Akademika Kimia*, vol. 6, no. 3, p. 154, Jan. 2018, doi: 10.22487/24775185.2017.v6.i3.9421.
- [23] Z. Maulia, "Inventarisasi Teknik Pembibitan Gaharu (*Gyrinops versteegii Gilg.*) di Jawa Timur dan Pemanfaatannya sebagai Karya Ilmiah Populer," 2015. <https://repository.unej.ac.id/xmlui/handle/123456789/74863>.
- [24] C. Herawati, R. Batubara, and E. B. M. Siregar, "Perubahan Kimia Kayu Pada Gubal Gaharu (*Aquilaria Malaccensis Lamk.*) hasil Rekayasa)(Wood Chemical Changes in Gubal Agarwood (*Aquilaria Malaccensis Lamk.*) Engineered," *Peronema Forestry Science Journal*, vol. 2, no. 1, pp. 117–125, 2013.