

DOI <http://dx.doi.org/10.36722/sst.v10i2.3788>

Pengaruh Variasi Jumlah Neuron dalam *Hidden Layer* Algoritma Pelatihan Levenberg-Marquardt Jaringan *Backpropagation: A Systematic Literature Review*

Ade Gilang Hendra Irianto^{1*}, Endah Sudarmilah¹

¹Magister Informatika, Fakultas Komunikasi dan Informatika, Universitas Muhammadiyah Surakarta, Jl. A. Yani, Mendungan, Pabelan, Kec. Kartasura, Kabupaten Sukoharjo, Jawa Tengah 57162.

Penulis untuk Korespondensi/E-mail: l208230006@student.ums.ac.id

Abstract - This analysis is done to determine and is a consideration for future research related to different types of problem solving by using the training algorithm of Backpropagation network. This study uses 4 steps selections in filter articles that will be used in literary studies, namely 1) Identification 2) Screening 3) Eligibility and 4) Included. The number of items filtered in this study is 73 articles. The article was filtered through the identification phase with a total of 205 articles, then in the screening process by assimilating the title and summary, then the eligible process with many articles filtered by 132 articles did not meet the requirements to get the final results of 73 articles for the analysis process. The number of nerve cells indicates that there is no rules that are determined related to the exact quantity of nerve cells in the hidden layer depending on all research needs and parameters applied in research. Although in some articles, the accuracy value is not briefly mentioned that the Levenberg-Marquardt training algorithm is effective in solving problems, in 21 articles filtered that the Levenberg- Marquardt training algorithm has an accuracy rate of over 90%, indicating that this algorithm can be an alternative choice as a problem-solving tool due to its effectiveness and optimal accuracy of results.

Abstrak - Analisis ini dilakukan untuk mengidentifikasi dan menjadi sebuah pertimbangan untuk penelitian di masa yang akan datang mengenai berbagai macam penyelesaian masalah menggunakan algoritma pelatihan jaringan Backpropagation. Penelitian ini menggunakan 4 tahapan seleksi dalam menyaring artikel yang akan digunakan dalam studi literatur yaitu 1) *Identification* 2) *Screening* 3) *Eligibility* dan 4) *Included*. Jumlah artikel yang tersaring dalam penelitian ini sebanyak 73 artikel. Artikel tersebut telah tersaring melalui tahapan *identification* dengan total awal sebanyak 205 artikel, lalu pada proses *screening* dengan menyamakan antara judul dengan abstrak, lalu proses *eligibility* dengan banyaknya artikel yang tersaring sebanyak 132 artikel yang tidak memenuhi persyaratan sehingga mendapatkan hasil akhir sebanyak 73 artikel untuk proses analisis. Banyaknya nilai varian neuron ini menandakan tidak ada nilai aturan yang pasti tentang jumlah pasti neuron dalam Hidden Layer semua tergantung pada kebutuhan penelitian serta faktor parameter yang diterapkan dalam penelitian. Meskipun dalam beberapa artikel tidak disebutkan nilai akurasi hanya disebutkan secara singkat bahwa algoritma pelatihan Levenberg-Marquardt efektif dalam pemecahan masalah, dalam 21 artikel yang sudah tersaring disebutkan bahwa algoritma pelatihan Levenberg-Marquardt memiliki nilai akurasi lebih dari 90% sehingga hal ini menandakan bahwa algoritma ini dapat menjadi alternatif pilihan sebagai alat bantu pemecahan masalah karena memiliki tingkat keefektifitasan dan keoptimalan dalam akurasi hasil yang baik.

Keywords - *Accuracy, Backpropagation, , Effectiveness, Hidden Layer, Levenberg-Marquardt Algorithm.*

PENDAHULUAN

Perkembangan teknologi berbasis *Artificial Intelligence* (AI) di era sekarang menjadi sebuah hal yang sangat umum digunakan dalam membantu berbagai permasalahan yang dialami oleh manusia sekarang. Salah satu yang menjadi perhatian di era sekarang adalah pemanfaatan jaringan *Backpropagation*. Jaringan *Backpropagation* banyak dimanfaatkan dalam penyelesaian masalah manusia seperti prediksi Tingkat kelarutan CO₂ dalam air pada tekanan dan suhu yang tinggi [1], prediksi parameter operasi dan daya keluaran dalam turbin angin [2], bahkan dalam 3 tahun ke belakang saat terjadi sebuah fenomena menyebarnya virus mematikan COVID-19, Jaringan *Backpropagation* juga sangat berpengaruh dalam prediksi seri waktu penyebarannya [3], selain prediksi dalam seri waktunya, Jaringan *Backpropagation* juga membantu dalam memprediksi efek dari vaksinasi COVID-19 itu sendiri [4]. Penerapan Jaringan *Backpropagation* tidak hanya terbatas dalam lingkup *Computer Science* saja, akan tetapi pemanfaatan Jaringan *Backpropagation* juga banyak diadaptasi untuk membantu menyelesaikan masalah dalam bidang ilmu yang lain seperti bidang Agrikultur. Pemanfaatan Jaringan *Backpropagation* telah diterapkan untuk memprediksi buah serta untuk membangun sistem prediksi yang cepat dan andal untuk produksi pertanian [5]. Sementara itu penelitian lain juga memanfaatkan Jaringan *Backpropagation* untuk memprediksi tingkat keausan spesifik untuk komposit LIM25/rOz [6].

Jaringan *Backpropagation* memiliki banyak algoritma di dalamnya. Salah satu algoritma yang populer digunakan adalah Levenberg-Marquardt. Penerapan algoritma Levenberg-Marquardt sudah banyak digunakan dalam berbagai penelitian. Contoh penerapan algoritma Levenberg-Marquardt adalah dalam menganalisis perpindahan panas dalam sirip trapesium berpori longitudinal dengan model konduksi panas *non-Fourier* [7]. Selain itu penerapan algoritma Levenberg-Marquardt juga dimanfaatkan untuk menguji kinerja dari model polusi air fraksional [8]. Algoritma Levenberg-Marquardt juga dimanfaatkan untuk memprediksi hasil keseluruhan *Gynura procumbens* dari etanol-air + ekstraksi CO₂ superkritik [9]. Algoritma Levenberg-Marquardt banyak digunakan karena memiliki tingkat akurasi yang sangat tinggi dalam memecahkan sebuah permasalahan. Algoritma ini mencapai tingkat akurasi hingga 99,62% dalam melakukan tes [10].

Pemanfaatan Jaringan *Backpropagation* dengan algoritma Pelatihan Levenberg-Marquardt dalam era modern seperti sekarang tidak akan jauh dari sebuah model yang diterapkan di dalamnya. Model neuron yang diterapkan dalam pemecahan masalah juga sangat berpengaruh dalam hasil akhir dari sebuah penelitian. Jumlah *Hidden Layer* dalam sebuah arsitektur Jaringan *Backpropagation* sangat bervariasi. Penelitian yang bertujuan untuk mengetahui perpindahan panas dari sistem pembakaran unggun terfluidisasi menggunakan 10 *neuron* dalam *Hidden Layer* [11]. Penelitian lain menggunakan variasi nilai *Hidden Layer* sebanyak 3 variasi yaitu 20 *neuron*, 15 *neuron*, dan 15 *neuron* dalam sebuah *Hidden Layer* untuk memprediksi waktu dari tekanan lubang bawah multifase yang mengalir di lubang sumur [12]. Penggunaan nilai *Hidden Layer* sebanyak 5 *neuron* juga diterapkan dalam sebuah penelitian untuk memprediksi suhu pada 2 meter di medan panas bumi Blawan [13] penggunaan berbagai variasi jumlah *neuron* dalam *Hidden Layer* juga digunakan untuk memprediksi penangkapan CO₂ oleh alumina aktif yang dimodifikasi, penelitian ini menggunakan variasi 25, 23, 7 dan 20 *neuron* yang terdapat dalam *Hidden Layer* nya.

Berdasarkan latar belakang yang telah diuraikan, Jaringan *Backpropagation* memiliki banyak algoritma pelatihan. Salah satu algoritma pelatihan Jaringan *Backpropagation* yang paling populer adalah Levenberg-Marquardt. Pengimplementasian algoritma tersebut tentunya tidak akan jauh dari penerapan model *neuron*. Dalam penelitian ini dapat ditarik beberapa *research question* antara lain.


- RQ1:** Berapa saja varian nilai *Hidden Layer* yang digunakan?
- RQ2:** Berapakah tingkat akurasi algoritma pelatihan Levenberg-Marquardt Jaringan *Backpropagation*?
- RQ3:** Apakah algoritma pelatihan Levenberg-Marquardt merupakan algoritma yang paling optimal dan paling baik dalam memecahkan sebuah masalah?

Penelitian ini bertujuan untuk memberikan acuan yang objektif dalam menentukan jumlah dan konfigurasi *hidden layer* yang optimal pada arsitektur jaringan syaraf tiruan dengan algoritma *Backpropagation*. Dengan melakukan analisis terhadap berbagai kombinasi struktur jaringan, penelitian ini dapat menghasilkan data empiris yang dapat dijadikan dasar dalam merancang model yang efisien dan akurat agar proses penelitian dan pelatihan menggunakan algoritma pelatihan dalam Jaringan *Backpropagation* menjadi lebih optimal.

METODE

Analysis Method

Penggunaan Jaringan *Backpropagation* menjadi populer dalam beberapa tahun terakhir untuk menyelesaikan berbagai macam permasalahan yang ada saat ini. Analisis ini dilakukan untuk mengidentifikasi dan menjadi sebuah pertimbangan untuk penelitian di masa yang akan datang mengenai berbagai macam penyelesaian masalah menggunakan algoritma pelatihan Jaringan *Backpropagation*. Dalam mencapai tujuan dari penelitian ini, digunakan Metodologi Tinjauan Literatur Sistematis. Metode Tinjauan Literatur yang sistematis dipilih karena memiliki kemampuan untuk melakukan pendekatan secara komprehensif, teliti serta objektif dalam proses tinjauan literatur [14]. Penelitian ini menggunakan 4 tahapan dalam penyusunannya. Tahapan ini menggunakan Kerangka SLR PRISMA untuk melakukan suatu pendekatan secara sistematis dan terstruktur untuk meninjau literatur ilmiah dengan tahapan yang digunakan meliputi, 1) *Identification*, 2) *Screening*, 3) *Eligibility*, 4) *Included*. Tahapan ini dapat dilihat pada gambar 1.



Gambar 1. Diagram Alir Tahapan Penelitian

Identification

Tahap ini dimulai dari proses identifikasi artikel melalui pencarian di dalam *database Science Direct* dan *Scopus* dengan pencarian menggunakan *keyword* yang sesuai dan telah ditentukan sebelumnya agar dalam proses identifikasi ini tetap terstruktur agar tetap pada tujuan awal dari penelitian ini. Pencarian yang telah dilakukan berhasil menemukan *paper* yang memiliki lingkup penelitian dalam bidang *Backpropagation* sebanyak 205 artikel. Proses selanjutnya melakukan penyaringan terhadap artikel yang didapatkan dengan menghapus duplikat artikel dari 2 *database*. Setelah menemukan artikel maka dapat melanjutkan ke tahap selanjutnya untuk melakukan *screening* terkait dengan artikel tersebut.

Screening

Proses *Identification* yang dilakukan sebelumnya, menggunakan kata kunci *Backpropagation* dan *Levenberg-Marquardt* yang dibatasi dengan melakukan penyaringan menggunakan batasan waktu selama 6 tahun terakhir. Tahapan selanjutnya adalah dengan melakukan proses *screening* menggunakan cara menyaring artikel yang memiliki kesesuaian antara judul dengan abstrak. Artikel yang tidak memiliki kesesuaian antara judul dan abstrak dianggap artikel yang tidak sesuai dan tidak digunakan dalam artikel ini. Proses penyaringan yang dilakukan memiliki hasil yaitu semua artikel sebanyak 205 tersebut memenuhi kriteria karena antara judul dan abstrak memiliki kesesuaian.

Eligibility

Tahapan selanjutnya dalam penelitian ini adalah proses *Eligibility*, dimana dalam proses ini artikel yang telah tersaring dilakukan proses penyaringan kembali untuk dinilai kelayakan artikel tersebut sebagai tinjauan literatur dengan menerapkan beberapa kriteria yang telah ditentukan seperti fokus artikel terhadap Jaringan *Backpropagation* dan Algoritma Pelatihan *Levenberg-Marquardt*, artikel tersebut memiliki *Full-Text*, serta Bahasa yang relevan. Bahasa yang relevan dalam artikel ini yang dimaksud adalah bahasa inggris dan bahasa indonesia. Proses ini berhasil melakukan penilaian kelayakan dengan jumlah artikel yang tidak layak sebagai tinjauan literatur sebanyak 132 artikel.

Included

Tahapan ini merupakan tahap akhir dalam proses penyaringan. Proses ini menghasilkan artikel yang layak sebagai tinjauan literatur sebanyak 73 artikel.

HASIL DAN PEMBAHASAN

Penelitian ini memiliki fokus terhadap Jaringan *Backpropagation* dengan penggunaan algoritma Pelatihan *Levenberg-Marquardt* yang dilihat dari nilai *Hidden Layer* sebagai parameter utama dalam proses seleksi artikel yang dilakukan. Tabel 1 menunjukkan artikel yang telah tersaring dan teridentifikasi yang disajikan dengan menunjukkan tahun serta artikelnya.

Tabel 1. Klasifikasi Artikel Berdasarkan Tahun

Tahun	Artikel	Jumlah
2018	[15] [16]	6
2019	[21] [22] [23] [24] [25] [26] [27] [28]	8
2020	[29] [30] [6] [31] [32] [33] [34] [35]	8
2021	[36] [37] [38]	3
2022	[2] [39] [40] [41] [42] [43] [44] [45] [46]	9
2023	[47] [48] [1] [49] [50] [51] [52] [53] [54] [55] [56] [7] [57] [58] [59] [60] [61] [62] [63] [64] [65] [66] [67]	23
2024	[68] [69] [70] [71] [72] [73] [74] [75] [76] [77] [78] [79] [80] [81] [82] [83]	16

Berdasarkan tabel 1 telah didapatkan 73 artikel yang telah disaring serta memiliki kriteria yang telah disusun berdasarkan judul, penulis serta tahun publikasi artikel. Pada awal pencarian artikel, telah dilakukan pembatasan terkait pencarian artikel yang digunakan yaitu dengan proses filter artikel berdasarkan tahun dan hanya artikel dari rentang waktu 2018 hingga 2024 (7 tahun terakhir) yang digunakan. Banyaknya artikel pada tahun 2018 sebanyak 6 artikel, tahun 2019 sebanyak 8 artikel, tahun 2020 sebanyak 8 artikel, tahun 2021 sebanyak 3 artikel, tahun 2022 sebanyak 9 artikel, tahun 2023 sebanyak 23 artikel serta tahun 2024 sebanyak 16 artikel. Semua artikel yang digunakan ini selanjutnya akan dianalisa lebih lanjut mengenai jumlah *neuron* pada *Hidden Layer* serta tingkat akurasi dari algoritma Pelatihan *Levenberg-Marquardt*.

Penggunaan Varian Nilai *Hidden Layer*

Proses ini tidak hanya memberikan informasi mengenai jumlah *hidden layer* yang digunakan dalam artikel yang terpilih, tetapi juga memungkinkan dilakukannya analisis lebih lanjut terhadap kecenderungan pemilihan konfigurasi tersebut dalam konteks performa model. Penggunaan jumlah *hidden layer* merupakan salah satu parameter kunci dalam arsitektur Jaringan *Backpropagation* yang secara langsung mempengaruhi kapasitas representasi dan kompleksitas model. Terlalu sedikit *hidden layer*

dapat menyebabkan model kurang mampu menangkap pola yang kompleks (*underfitting*), sedangkan penggunaan *hidden layer* yang berlebihan berisiko menyebabkan *overfitting* serta peningkatan waktu komputasi yang tidak efisien. Oleh karena itu penting untuk mengidentifikasi pola atau justifikasi empiris di balik pemilihan jumlah *hidden layer* dalam literatur. Hal tersebut agar dapat dijadikan dasar dalam pengambilan keputusan desain arsitektur jaringan yang lebih rasional dan berbasis data. Penggunaan nilai *Hidden Layer* dapat dilihat pada tabel 2.

Tabel 2. Klasifikasi Variasi Jumlah Neuron dalam *Hidden Layer*

Jumlah Neuron	Artikel
0-20	[6] [16] [17] [18] [19] [20] [21] [23] [24] [25] [26] [27] [28] [29] [30] [31] [32] [33] [34] [35] [36] [37] [38] [2] [39] [41] [42] [43] [44] [45] [46] [47] [48] [49] [50] [51] [54] [55] [7] [60] [61] [62] [63] [64] [65] [67] [68] [69] [70] [71] [72] [73] [74] [76] [77] [78] [80] [83]
21-40	[15] [22] [2] [44] [48] [53] [56] [66] [69] [81]
41-60	[2] [75] [82]
61-80	[2] [44] [59] [79] [81]
81-100	-
>100	[44] [58]
Tidak didefinisikan	[52] [1] [57]

Berdasarkan tabel 2 mengenai jumlah varian nilai *Hidden Layer* yang digunakan pada seluruh artikel diketahui bahwa tidak ada standar pasti terkait dengan penggunaan *Hidden Layer*. Seluruh penelitian menerapkan variasi jumlah nilai pada *Hidden Layer* sesuai dengan kebutuhan penelitian yang dilakukan. Tahapan selanjutnya dalam penelitian ini adalah mengetahui nilai akurasi dari algoritma Pelatihan *Levenberg-Marquardt* Jaringan *Backpropagation*.

Tingkat Akurasi Algoritma Pelatihan *Levenberg-Marquardt*

Proses ini merupakan tahapan yang dilakukan untuk mengetahui tingkat akurasi algoritma pelatihan *Levenberg-Marquardt* sebagai salah satu solusi penerapan Jaringan *Backpropagation* dalam menyelesaikan sebuah kasus. Tahapan ini dapat dilihat pada tabel 3.

Tabel 3. Tingkat Akurasi Algoritma Pelatihan Levenberg-Marquardt

Tingkat Akurasi	Artikel
< 90%	[21] [22] [27] [30] [46] [81]
> 90%	[15] [17] [28] [29] [6] [31] [32] [34] [36] [38] [39] [40] [47] [1] [49] [53] [58] [66] [68] [77] [78]
Lainnya	[18] [19] [20] [23] [24] [25] [26] [33] [35] [37] [2] [41] [42] [43] [44] [45] [48] [50] [51] [52] [54] [55] [56] [7] [57] [59] [60] [61] [62] [63] [64] [65] [67] [69] [70] [71] [72] [73] [74] [75] [76] [79] [80] [82] [83]

Berdasarkan hasil identifikasi tingkat akurasi algoritma pelatihan Levenberg-Marquardt pada tabel 3, dapat diketahui bahwa ada beberapa faktor yang menjadikan sebagian artikel yang tersaring tidak menunjukkan nilai angka persentase keakuratan algoritma pelatihan Levenberg-Marquardt. Hal ini dikarenakan pada artikel tersebut tidak mencari nilai akurasi algoritmanya tetapi algoritma Levenberg-Marquardt Jaringan *Backpropagation* digunakan untuk mencari *error* dalam memprediksi suatu kasus. Beberapa artikel juga hanya memberikan sebuah kesimpulan yang menyatakan bahwa algoritma tersebut efektif. Namun dalam artikel yang telah tersaring juga menunjukkan bahwa Algoritma pelatihan Levenberg-Marquardt memiliki rata-rata tingkat akurasi lebih dari 90% berdasarkan identifikasi yang telah dilakukan. Sedangkan untuk artikel yang memiliki nilai akurasi <90% yang berjumlah 6 artikel. Faktor yang menyebabkan nilai akurasi ada dibawah angka 90% dikarenakan penggunaan 2 *hidden Layer*. Serta ada artikel yang menggunakan nilai *Input Layer* yang jumlahnya lebih banyak dari pada nilai *Hidden Layer*. Faktor penggunaan parameter jaringan juga menjadi. Hal yang krusial dalam proses pelatihan sehingga berdampak pada hasil akhir.

KESIMPULAN

Berdasarkan data yang telah terkumpul dari artikel yang sebelumnya telah tersaring dengan berfokus pada Jaringan *Backpropagation* dan algoritma Pelatihan Levenberg-Marquardt maka dapat diambil kesimpulan sebagai berikut, (1) Artikel yang telah tersaring diambil dari rentang waktu 6 tahun kebelakang dengan persentase tahun 2018 hingga tahun 2024. Banyaknya artikel pada tahun 2018

sebanyak 6 artikel, tahun 2019 sebanyak 8 artikel, tahun 2020 sebanyak 8 artikel, tahun 2021 sebanyak 2 artikel, tahun 2022 sebanyak 9 artikel, tahun 2023 sebanyak 23 artikel serta tahun 2024 sebanyak 16 artikel, (2) Berbagai nilai varian neuron dalam *Hidden Layer* diterapkan dalam artikel yang telah tersaring. Banyaknya nilai varian neuron ini menandakan bahwa tidak ada nilai aturan yang pasti tentang jumlah pasti neuron dalam *Hidden Layer* semua tergantung pada kebutuhan penelitian serta faktor parameter yang diterapkan dalam penelitian, (3) Berdasarkan 73 artikel yang telah disaring dan masuk dalam tahapan analisis, sebanyak 6 artikel memiliki nilai akurasi <90%. Sedangkan untuk 21 artikel memiliki nilai akurasi yang sangat baik mencapai >90%. Untuk artikel yang tidak menyebutkan nilai akurasi, didapati bahwa dalam artikel tersebut berfokus pada pencarian *error* menggunakan algoritma Levenberg-Marquardt yang ada pada Jaringan *Backpropagation*.

Penelitian ini menunjukan bahwa algoritma Pelatihan Levenberg-Marquardt merupakan salah satu algoritma yang direkomendasikan untuk memecahkan masalah karena tingkat akurasi serta keefektifannya dalam bekerja. Dengan adanya artikel ini dapat menjadi rujukan dalam pemilihan nilai *Hidden Layer* untuk memaksimalkan hasil akhir dari penelitian yang akan dilakukan kedepannya.

REFERENSI

- [1] Z. Khoshraftar and A. Ghaemi, "Prediction of CO2 solubility in water at high pressure and temperature via deep learning and response surface methodology," *Case Studies in Chemical and Environmental Engineering*, vol. 7, no. March, p. 100338, 2023, doi: 10.1016/j.cscee.2023.100338.
- [2] J. Taghinezhad and S. Sheidaei, "Prediction of operating parameters and output power of ducted wind turbine using artificial neural networks," *Energy Reports*, vol. 8, pp. 3085–3095, 2022, doi: 10.1016/j.egyr.2022.02.065.
- [3] L. S. de Oliveira, S. B. Gruetzmacher, and J. P. Teixeira, "Covid-19 time series prediction," *Procedia Comput Sci*, vol. 181, no. 2019, pp. 973–980, 2021, doi: 10.1016/j.procs.2021.01.254.
- [4] E. N. Ghaleini and M. J. Shaibani, "Investigating the effect of vaccinated population on the COVID-19 prediction using FA and ABC-based feed-forward neural

- networks,” *Heliyon*, vol. 9, no. 2, p. e13672, 2023, doi: 10.1016/j.heliyon.2023.e13672.
- [5] T. Khan, J. Qiu, M. A. A. Qureshi, M. S. Iqbal, R. Mehmood, and W. Hussain, “Agricultural Fruit Prediction Using Deep Neural Networks,” *Procedia Comput Sci*, vol. 174, no. 2019, pp. 72–78, 2020, doi: 10.1016/j.procs.2020.06.058.
- [6] M. Kannaiyan, G. Karthikeyan, and J. G. Thankachi Raghuvaram, “Prediction of specific wear rate for LM25/ZrO2 composites using Levenberg-Marquardt backpropagation algorithm,” *Journal of Materials Research and Technology*, vol. 9, no. 1, pp. 530–538, 2020, doi: 10.1016/j.jmrt.2019.10.082.
- [7] J. S. Goud *et al.*, “Heat transfer analysis in a longitudinal porous trapezoidal fin by non-Fourier heat conduction model: An application of artificial neural network with Levenberg–Marquardt approach,” *Case Studies in Thermal Engineering*, vol. 49, no. July, p. 103265, 2023, doi: 10.1016/j.csite.2023.103265.
- [8] Z. Sabir, R. Sadat, M. R. Ali, S. Ben Said, and M. Azhar, “A numerical performance of the novel fractional water pollution model through the Levenberg-Marquardt backpropagation method,” *Arabian Journal of Chemistry*, vol. 16, no. 2, p. 104493, 2023, doi: 10.1016/j.arabjc.2022.104493.
- [9] S. A. Idris, M. Markom, N. Abd Rahman, and J. Mohd Ali, “Prediction of overall yield of *Gynura procumbens* from ethanol-water + supercritical CO2 extraction using artificial neural network model,” *Case Studies in Chemical and Environmental Engineering*, vol. 5, no. December 2021, p. 100175, 2022, doi: 10.1016/j.cscee.2021.100175.
- [10] R. Sekhar, P. Shah, S. Panchal, M. Fowler, and R. Fraser, “Distance to empty soft sensor for ford escape electric vehicle,” *Results in Control and Optimization*, vol. 9, no. May, p. 100168, 2022, doi: 10.1016/j.rico.2022.100168.
- [11] N. Doner, K. Ciddi, I. B. Yalcin, and M. Sarivaz, “Artificial neural network models for heat transfer in the freeboard of a bubbling fluidised bed combustion system,” *Case Studies in Thermal Engineering*, vol. 49, no. February, p. 103145, 2023, doi: 10.1016/j.csite.2023.103145.
- [12] C. C. Nwanwe, U. I. Duru, C. Anyadiiegwu, and A. I. B. Ekejuba, “An artificial neural network visible mathematical model for real-time prediction of multiphase flowing bottom-hole pressure in wellbores,” *Petroleum Research*, vol. 8, no. 3, pp. 370–385, 2023, doi: 10.1016/j.ptlrs.2022.10.004.
- [13] A. Afandi, N. Lusi, I. G. N. B. Catrawedarma, S. Subono, and B. Rudiyanto, “Prediction of temperature in 2 meters temperature probe survey in Blawan geothermal field using artificial neural network (ANN) method,” *Case Studies in Thermal Engineering*, vol. 38, no. October 2021, p. 102309, 2022, doi: 10.1016/j.csite.2022.102309.
- [14] S. S. Bhattacharya, K. Govindan, S. G. Dastidar, and P. Sharma, “Applications of artificial intelligence in closed-loop supply chains: Systematic literature review and future research agenda,” *Transp Res E Logist Transp Rev*, vol. 184, no. December 2023, p. 103455, 2024, doi: 10.1016/j.tre.2024.103455.
- [15] R. Zhou, D. Wu, L. Fang, A. Xu, and X. Lou, “A Levenberg-Marquardt backpropagation neural network for predicting forest growing stock based on the least-squares equation fitting parameters,” *Forests*, vol. 9, no. 12, pp. 1–16, 2018, doi: 10.3390/f9120757.
- [16] C. Crisosto, M. Hofmann, R. Mubarak, and G. Seckmeyer, “One-hour prediction of the global solar irradiance from all-sky images using artificial neural networks,” *Energies (Basel)*, vol. 11, no. 11, 2018, doi: 10.3390/en11112906.
- [17] A. C. Affam, M. Chaudhuri, C. C. Wong, and C. S. Wong, “Artificial Neural Network (ANN) Modeling for Prediction of Pesticide Wastewater Degradation by FeGAC/H2O2 Process,” *E3S Web of Conferences*, vol. 65, 2018, doi: 10.1051/e3sconf/20186505004.
- [18] J. W. Lin, C. T. Chao, and J. S. Chiou, “Backpropagation neural network as earthquake early warning tool using a new modified elementary Levenberg-Marquardt Algorithm to minimise backpropagation errors,” *Geoscientific Instrumentation, Methods and Data Systems*, vol. 7, no. 3, pp. 235–243, 2018, doi: 10.5194/gi-7-235-2018.
- [19] P. T. T. Ngo *et al.*, “A novel hybrid swarm optimized multilayer neural network for spatial prediction of flash floods in tropical areas using sentinel-1 SAR imagery and geospatial data,” *Sensors (Switzerland)*, vol. 18, no. 11, 2018, doi: 10.3390/s18113704.
- [20] R. Kasem, D. Alabdeh, R. Noori, and A. Karbassi, “A software sensor for in-situ monitoring of the 5-day biochemical oxygen demand,” *Rudarsko Geolosko Naftni Zbornik*, vol. 33, no. 1, pp. 15–22, 2018, doi: 10.17794/rgn.2018.1.3.
- [21] E. T. Lau, L. Sun, and Q. Yang, “Modelling, prediction and classification of student

- academic performance using artificial neural networks,” *SN Appl Sci*, vol. 1, no. 9, pp. 1–10, 2019, doi: 10.1007/s42452-019-0884-7.
- [22] H. S. Abdelkhalek, H. Medhat, I. Ziedan, and M. Amal, “Simulation and prediction for a satellite temperature sensors based on artificial neural network,” *Journal of Aerospace Technology and Management*, vol. 11, pp. 1–14, 2019, doi: 10.5028/jatm.v11.1055.
- [23] O. A. Olalere, N. H. Abdurahman, R. bin M. Yunus, and O. R. Alara, “Multi-response optimization and neural network modeling for parameter precision in heat reflux extraction of spice oleoresins from two pepper cultivars (*Piper nigrum*),” *J King Saud Univ Sci*, vol. 31, no. 4, pp. 789–797, 2019, doi: 10.1016/j.jksus.2017.09.010.
- [24] L. Zhang, H. Li, and X. G. Kong, “Evolving feedforward artificial neural networks using a two-stage approach,” *Neurocomputing*, vol. 360, pp. 25–36, 2019, doi: 10.1016/j.neucom.2019.03.097.
- [25] J. Pribbenow, M. Mejauschek, P. Landgraf, T. Grund, G. Bräuer, and T. Lampke, “Neural network for prediction of hardness profiles for steel alloys after plasma nitriding,” *IOP Conf Ser Mater Sci Eng*, vol. 480, no. 1, 2019, doi: 10.1088/1757-899X/480/1/012019.
- [26] M. Fayed, M. Elhadary, H. A. Abderrahmane, and B. N. Zakher, “The ability of forecasting flapping frequency of flexible filament by artificial neural network,” *Alexandria Engineering Journal*, vol. 58, no. 4, pp. 1367–1374, 2019, doi: 10.1016/j.aej.2019.11.007.
- [27] D. Bhavsar, M. Bhatt, M. Choksi, and G. Nagababu, “Comparative analysis of Artificial Neural Networks with conventional methods for extrapolation of wind speed at an elevated height,” *IOP Conf Ser Mater Sci Eng*, vol. 605, no. 1, 2019, doi: 10.1088/1757-899X/605/1/012011.
- [28] W. S. Chan, R. A. Samah, N. Zainol, A. S. Fakharudin, S. A. Aziz, and L. Y. Phang, “Modeling of vanillin adsorption from aqueous solution using resin H103 by artificial neural network,” *IOP Conf Ser Mater Sci Eng*, vol. 702, no. 1, 2019, doi: 10.1088/1757-899X/702/1/012048.
- [29] S. Tangjitsitharoen, “Comparison of neural networks and regression analysis to predict in-process straightness in CNC turning,” *Procedia Manuf*, vol. 51, pp. 222–227, 2020, doi: 10.1016/j.promfg.2020.10.032.
- [30] A. A. Kasim, M. Bakri, and A. Septiarini, “The Artificial Neural Networks (ANN) for Batik Detection Based on Textural Features,” *Proceedings of the 7th Mathematics, Science, and Computer Science Education International Seminar, MSCEIS 2019*, 2020, doi: 10.4108/eai.12-10-2019.2296538.
- [31] M. A. Jallal, A. El Yassini, S. Chabaa, A. Zeroual, and S. Ibnyaich, “AI data driven approach-based endogenous inputs for global solar radiation forecasting,” *Ingenierie des Systemes d’Information*, vol. 25, no. 1, pp. 27–34, 2020, doi: 10.18280/isi.250104.
- [32] J. N. Ogunbo, O. A. Alagbe, M. I. Oladapo, and C. Shin, “N-*Hidden Layer* artificial neural network architecture computer code: geophysical application example,” *Heliyon*, vol. 6, no. 6, p. e04108, 2020, doi: 10.1016/j.heliyon.2020.e04108.
- [33] D. S. Kapoor and A. K. Kohli, “Intelligence-based channel equalization for 4x1 sfbc-ofdm receiver,” *Intelligent Automation and Soft Computing*, vol. 26, no. 3, pp. 439–446, 2020, doi: 10.32604/iasc.2020.013920.
- [34] S. Verma, G. T. Thampi, and M. Rao, “ANN based method for improving gold price forecasting accuracy through modified gradient descent methods,” *IAES International Journal of Artificial Intelligence*, vol. 9, no. 1, pp. 46–57, 2020, doi: 10.11591/ijai.v9.i1.pp46-57.
- [35] T. Y. Liu, P. Zhang, J. Wang, and Y. F. Ling, “Compressive strength prediction of PVA fiber-reinforced cementitious composites containing nano-SiO₂ using BP neural network,” *Materials*, vol. 13, no. 3, 2020, doi: 10.3390/ma13030521.
- [36] Y. J. Wong, K. B. Mustapha, Y. Shimizu, A. Kamiya, and S. K. Arumugasamy, “Development of surrogate predictive models for the nonlinear elasto-plastic response of medium density fibreboard-based sandwich structures,” *International Journal of Lightweight Materials and Manufacture*, vol. 4, no. 3, pp. 302–314, 2021, doi: 10.1016/j.ijlmm.2021.02.002.
- [37] M. A. Z. Raja *et al.*, “Cattaneo-christov heat flux model of 3D hall current involving biconvection nanofluidic flow with Darcy-Forchheimer law effect: Backpropagation neural networks approach,” *Case Studies in Thermal Engineering*, vol. 26, no. April, p. 101168, 2021, doi: 10.1016/j.csite.2021.101168.
- [38] M. R. Mohammadi, A. H. Sarapardeh, M. Schaffie, M. M. Husein, and M. Ranjbar, “Application of cascade forward neural network and group method of data handling to

- modeling crude oil pyrolysis during thermal enhanced oil recovery,” *J Pet Sci Eng*, vol. 205, no. April, p. 108836, 2021, doi: 10.1016/j.petrol.2021.108836.
- [39] R. Vijayakumar and N. Pannirselvam, “Multi-objective optimisation of mild steel embossed plate shear connector using artificial neural network-integrated genetic algorithm,” *Case Studies in Construction Materials*, vol. 17, no. July, p. e01560, 2022, doi: 10.1016/j.cscm.2022.e01560.
- [40] D. K. Jana, P. Bhunia, S. Das Adhikary, and B. Bej, “Optimization of Effluents Using Artificial Neural Network and Support Vector Regression in Detergent Industrial Wastewater Treatment,” *Cleaner Chemical Engineering*, vol. 3, no. April, p. 100039, 2022, doi: 10.1016/j.clce.2022.100039.
- [41] D. S. Adelekan, O. S. Ohunakin, and B. S. Paul, “Artificial intelligence models for refrigeration, air conditioning and heat pump systems,” *Energy Reports*, vol. 8, pp. 8451–8466, 2022, doi: 10.1016/j.egyr.2022.06.062.
- [42] I. Veza *et al.*, “Improved prediction accuracy of biomass heating value using proximate analysis with various ANN training algorithms,” *Results in Engineering*, vol. 16, no. October, p. 100688, 2022, doi: 10.1016/j.rineng.2022.100688.
- [43] F. Faraji, C. Santim, P. L. Chong, and F. Hamad, “Two-phase flow pressure drop modelling in horizontal pipes with different diameters,” *Nuclear Engineering and Design*, vol. 395, no. July, p. 111863, 2022, doi: 10.1016/j.nucengdes.2022.111863.
- [44] C. Couto, “Neural network models for the critical bending moment of uniform and tapered beams,” *Structures*, vol. 41, no. May, pp. 1746–1762, 2022, doi: 10.1016/j.istruc.2022.05.096.
- [45] K. Nwosu-Obieogu, E. Grace, K. F. Adekunle, L. I. Chiemenem, F. O. Aguele, and G. W. Dzarma, “In-situ selective epoxidation of *Colocynthis Vulgaris* shrad seed oil for the synthesis of a methacrylated biobased resin; An artificial neural network (ANN) modelling approach,” *Cleaner and Circular Bioeconomy*, vol. 3, no. October, p. 100028, 2022, doi: 10.1016/j.clcb.2022.100028.
- [46] K. Mukdasai, Z. Sabir, M. A. Z. Raja, R. Sadat, M. R. Ali, and P. Singkibud, “A numerical simulation of the fractional order Leptospirosis model using the supervise neural network,” *Alexandria Engineering Journal*, vol. 61, no. 12, pp. 12431–12441, 2022, doi: 10.1016/j.aej.2022.06.013.
- [47] G. Cuahuizo-Huitzil *et al.*, “Artificial Neural Networks for Predicting the Diameter of Electrospun Nanofibers Synthesized from Solutions/Emulsions of Biopolymers and Oils,” *Materials*, vol. 16, no. 16, 2023, doi: 10.3390/ma16165720.
- [48] A. Q. Khan, H. A. Awan, M. Rasul, Z. A. Siddiqi, and A. Pimanmas, “Optimized artificial neural network model for accurate prediction of compressive strength of normal and high strength concrete,” *Cleaner Materials*, vol. 10, no. October, p. 100211, 2023, doi: 10.1016/j.clema.2023.100211.
- [49] D. J. Rufina R, H. Uthayakumar, and P. Thangavelu, “Prediction of the size of green synthesized silver nanoparticles using RSM-ANN-LM hybrid modeling approach,” *Chemical Physics Impact*, vol. 6, no. May, p. 100231, 2023, doi: 10.1016/j.chphi.2023.100231.
- [50] T. A. woldegiyorgis *et al.*, “Harnessing solar power: Predicting photovoltaic potential in fiche, oromia, ethiopia with artificial neural networks,” *Sci Afr*, vol. 21, no. March, p. e01884, 2023, doi: 10.1016/j.sciaf.2023.e01884.
- [51] F. Aslani, J. Yu, Y. Zhang, and A. Valizadeh, “Development of prediction models for evaluation of alkali-silica reaction in concrete,” *Case Studies in Construction Materials*, vol. 19, no. August, p. e02465, 2023, doi: 10.1016/j.cscm.2023.e02465.
- [52] A. S. Baazeem, M. S. Arif, and K. Abodayeh, “An Efficient and Accurate Approach to Electrical Boundary Layer Nanofluid Flow Simulation: A Use of Artificial Intelligence,” *Processes*, vol. 11, no. 9, 2023, doi: 10.3390/pr11092736.
- [53] F. T. Putri *et al.*, “Human Walking Gait Classification Utilizing an Artificial Neural Network for the Ergonomics Study of Lower Limb Prosthetics,” *Prosthesis*, vol. 5, no. 3, pp. 647–665, 2023, doi: 10.3390/prosthesis5030046.
- [54] E. Thangapandian, P. Palanisamy, S. K. Selvaraj, U. Chadha, and M. Khanna, “Detailed experimentation and prediction of thermophysical properties in lauric acid-based nanocomposite phase change material using artificial neural network,” *J Energy Storage*, vol. 74, no. PB, p. 109345, 2023, doi: 10.1016/j.est.2023.109345.
- [55] Z. Huang, Q. Haider, Z. Sabir, M. Arshad, B. K. Siddiqui, and M. M. Alam, “A neural network computational structure for the

- fractional order breast cancer model,” *Sci Rep*, vol. 13, no. 1, pp. 1–14, 2023, doi: 10.1038/s41598-023-50045-z.
- [56] E. Gheller, S. Chatterton, D. Panara, G. Turini, and P. Pennacchi, “Artificial neural network for tilting pad journal bearing characterization,” *Tribol Int*, vol. 188, no. June, p. 108833, 2023, doi: 10.1016/j.triboint.2023.108833.
- [57] Z. Sabir, S. Ben Said, and Q. Al-Mdallal, “A fractional order numerical study for the influenza disease mathematical model,” *Alexandria Engineering Journal*, vol. 65, pp. 615–626, 2023, doi: 10.1016/j.aej.2022.09.034.
- [58] A. N. Sharkawy, A. Ma’arif, Furizal, R. Sekhar, and P. Shah, “A Comprehensive Pattern Recognition Neural Network for Collision Classification Using Force Sensor Signals,” *Robotics*, vol. 12, no. 5, pp. 1–20, 2023, doi: 10.3390/robotics12050124.
- [59] B. K. Sharma, P. Sharma, N. K. Mishra, and U. Fernandez-Gamiz, “Darcy-Forchheimer hybrid nanofluid flow over the rotating Riga disk in the presence of chemical reaction: Artificial neural network approach,” *Alexandria Engineering Journal*, vol. 76, pp. 101–130, 2023, doi: 10.1016/j.aej.2023.06.014.
- [60] M. T. Hussain, A. Sarwar, M. Tariq, S. Urooj, A. BaQais, and M. A. Hossain, “An Evaluation of ANN Algorithm Performance for MPPT Energy Harvesting in Solar PV Systems,” *Sustainability (Switzerland)*, vol. 15, no. 14, 2023, doi: 10.3390/su151411144.
- [61] I. U. Nzelibe and T. O. Idowu, “Refinement of global gridded ray-traced Zenith tropospheric delay over Nigeria based on local GNSS network observations,” *Geosystems and Geoenvironment*, vol. 2, no. 1, p. 100137, 2023, doi: 10.1016/j.geogeo.2022.100137.
- [62] M. Sedighkia and B. Datta, “Detecting land use changes using hybrid machine learning methods in the Australian tropical regions,” *GeoJournal*, vol. 88, no. s1, pp. 241–253, 2023, doi: 10.1007/s10708-022-10678-5.
- [63] P. Kaswan, M. Kumar, and M. Kumari, “Analysis of a bioconvection flow of magnetocross nanofluid containing gyrotactic microorganisms with activation energy using an artificial neural network scheme,” *Results in Engineering*, vol. 17, no. January, p. 101015, 2023, doi: 10.1016/j.rineng.2023.101015.
- [64] R. Mukhtar, C. Y. Chang, M. A. Z. Raja, and N. I. Chaudhary, “Design of Intelligent Neuro-Supervised Networks for Brain Electrical Activity Rhythms of Parkinson’s Disease Model,” *Biomimetics*, vol. 8, no. 3, 2023, doi: 10.3390/biomimetics8030322.
- [65] K. S. Nisar, F. Sahar, M. Asif Zahoor Raja, and M. Shoaib, “Intelligent neuro-computing to analyze the awareness programs of fractional epidemic system outbreaks,” *J King Saud Univ Sci*, vol. 35, no. 5, p. 102691, 2023, doi: 10.1016/j.jksus.2023.102691.
- [66] J. A. Shuhli *et al.*, “An Efficient and Accurate Approach to Electrical Boundary Layer Nanofluid Flow Simulation: A Use of Artificial Intelligence,” *Materials*, vol. 12, no. 1, pp. 3–21, Aug. 2023, doi: 10.1515/eng-2022-0590.
- [67] B. Muktar, V. Fono, and M. Zongo, “Predictive Modeling of Signal Degradation in Urban VANETs Using Artificial Neural Networks,” *Electronics (Switzerland)*, vol. 12, no. 18, pp. 1–18, 2023, doi: 10.3390/electronics12183928.
- [68] Z. A. H. Hamza, “Predicted evaporation in Basrah using artificial neural networks,” *Open Engineering*, vol. 14, no. 1, 2024, doi: 10.1515/eng-2022-0590.
- [69] Z. Khoshraftar, A. Ghaemi, and A. Hemmati, “Comprehensive investigation of isotherm, RSM, and ANN modeling of CO₂ capture by multi-walled carbon nanotube,” *Sci Rep*, vol. 14, no. 1, pp. 1–29, 2024, doi: 10.1038/s41598-024-55836-6.
- [70] K. U. Rehman, W. Shatanawi, and M. Y. Malik, “Group theoretic thermal analysis (GTTA) of Powell-Eyring fluid flow with Identical free stream (FS) and heated stretched porous (HSP) boundaries: AI Decisions,” *Case Studies in Thermal Engineering*, vol. 55, no. October 2023, p. 104101, 2024, doi: 10.1016/j.csite.2024.104101.
- [71] M. T. Mezher, A. Pereira, T. Trzepieciński, and J. Acevedo, “Artificial Neural Networks and Experimental Analysis of the Resistance Spot Welding Parameters Effect on the Welded Joint Quality of AISI 304,” *Materials*, vol. 17, no. 9, 2024, doi: 10.3390/ma17092167.
- [72] V. Mahesh, “Machine learning assisted nonlinear deflection analysis of agglomerated carbon nanotube core smart sandwich plate with three-phase magneto-electro-elastic skin,” *Proceedings of the Institution of Mechanical Engineers, Part L: Journal of Materials: Design and Applications*, vol. 238, no. 1, pp. 3–21, 2024, doi: 10.1177/14644207231180459.
- [73] A. Patel, K. P. Singh, A. K. Roul, K. N. Agrawal, K. Singh, and M. Kumar, “Prediction of Paddy Straw Mechanical Properties under Varying Moisture Content and Loading Rate using ANN,” *J Sci Ind Res (India)*, vol. 83, no.

- 1, pp. 76–83, 2024, doi: 10.56042/jsir.v83i1.5418.
- [74] M. Shoaib, S. U. Saqib, K. S. Nisar, M. A. Z. Raja, and I. A. Mohammed, “Numerical treatment for the desirability of Hall current and activation energy in the enhancement of heat transfer in a nanofluidic system,” *Arabian Journal of Chemistry*, vol. 17, no. 2, p. 105526, 2024, doi: 10.1016/j.arabjc.2023.105526.
- [75] H. Shahzad, M. N. Sadiq, Z. Li, S. Algarni, T. Alqahtani, and K. Irshad, “Scientific computing of radiative heat transfer with thermal slip effects near stagnation point by artificial neural network,” *Case Studies in Thermal Engineering*, vol. 54, no. January, p. 104024, 2024, doi: 10.1016/j.csite.2024.104024.
- [76] K. C. Shikhar, K. P. Bhattarai, T. De Shan, S. Mishra, I. Joshi, and A. K. Singh, “Comprehensive performance analysis of training functions in flow prediction mode using artificial neural network,” *Water SA*, vol. 50, no. 2, pp. 190–200, 2024, doi: 10.17159/wsa/2024.v50.i2.4099.
- [77] J. Sumathi, P. Aravind, and G. Gandhimathi, “Smart solutions for dissolved oxygen control in semi-batch fermenters: A machine learning approach,” *Desalination Water Treat*, vol. 317, no. December 2023, p. 100004, 2024, doi: 10.1016/j.dwt.2024.100004.
- [78] C. Windarto and O. Lim, “A neural network approach on forecasting spark duration effect on in-cylinder performance of a large bore compression ignition engine fueled with propane direct injection,” *Fuel Processing Technology*, vol. 257, no. September 2023, p. 108088, 2024, doi: 10.1016/j.fuproc.2024.108088.
- [79] S. Nasir, A. S. Berrouk, and T. Gul, “Analysis of chemical reactive nanofluid flow on stretching surface using numerical soft computing approach for thermal enhancement,” *Engineering Applications of Computational Fluid Mechanics*, vol. 18, no. 1, 2024, doi: 10.1080/19942060.2024.2340609.
- [80] A. Khan, F. Aljuaydi, Z. Khan, and S. Islam, “Numerical analysis of thermophoretic particle deposition on 3D Casson nanofluid: Artificial neural networks-based Levenberg-Marquardt algorithm,” *Open Physics*, vol. 22, no. 1, 2024, doi: 10.1515/phys-2023-0181.
- [81] M. Troiano, E. Nobile, F. Mangini, M. Mastrogiuseppe, C. Conati Barbaro, and F. Frezza, “A Comparative Analysis of the Bayesian Regularization and Levenberg–Marquardt Training Algorithms in Neural Networks for Small Datasets: A Metrics Prediction of Neolithic Laminar Artefacts,” *Information (Switzerland)*, vol. 15, no. 5, 2024, doi: 10.3390/info15050270.
- [82] I. Ahmad, H. Qureshi, M. A. Z. Raja, S. I. Hussain, and S. Fatima, “A novel design of stochastic approximation treatment of longitudinal rectangular fin dynamical model,” *Case Studies in Thermal Engineering*, vol. 54, no. January, p. 104042, 2024, doi: 10.1016/j.csite.2024.104042.
- [83] K. U. Rehman and W. Shatanawi, “Lie symmetry based neural networking analysis for Powell–Eyring fluid flow with heat and mass transfer effects,” *International Journal of Thermofluids*, vol. 22, no. February, p. 100602, 2024, doi: 10.1016/j.ijft.2024.100602.