

Pemanfaatan Algoritma Levenberg-Marquardt untuk Analisis Prediksi Persentase Penduduk yang Melakukan Pengobatan Sendiri

Surya Darma*, Fahmi Firzada

STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: 1.*suryadarma@amiktunasbangsa.ac.id, 2*fahmifirzada@amiktunasbangsa.ac.id

Email Penulis Korespondensi: suryadarma@amiktunasbangsa.ac.id

Submitted: 29/10/2024; Accepted: 30/11/2024; Published: 30/11/2024

Abstrak—Pengobatan sendiri atau *self-medication* merupakan praktik di mana individu menggunakan obat-obatan atau melakukan pengobatan tanpa adanya resep dokter atau pengawasan medis. Fenomena ini telah menjadi isu kesehatan yang penting di Indonesia, khususnya di kota Pematangsiantar dan kabupaten Simalungun, di mana banyak penduduk yang cenderung melakukan pengobatan sendiri tanpa memperoleh konsultasi medis yang memadai. Oleh sebab itu tujuan dari penelitian ini adalah untuk menganalisis prediksi persentase perkembangan kemandirian kesehatan penduduk yang melakukan pengobatan sendiri di kota Pematangsiantar dan kabupaten Simalungun, menggunakan algoritma *Levenberg-Marquardt*. Data penelitian berupa data times-series persentase penduduk yang melakukan pengobatan sendiri di kota Pematangsiantar dan kabupaten Simalungun tahun 2018-2023 yang diperoleh dari Badan Pusat Statistik Sumatera Utara. Analisis dilakukan dengan menggunakan lima model arsitektur, yaitu 4-5-1, 4-10-1, 4-15-1, 4-20-1, dan 4-25-1. Hasil penelitian menunjukkan bahwa algoritma *Levenberg-Marquardt* dengan model arsitektur 4-15-1 memberikan performa terbaik dengan nilai *Mean Squared Error* (MSE) terkecil dibandingkan dengan model arsitektur yang lain, yakni sebesar 0,0268691174. Hasil penelitian ini diharapkan dapat membantu pemerintah daerah dalam memberikan informasi tentang perkembangan persentase penduduk yang melakukan pengobatan sendiri di kota Pematangsiantar dan kabupaten simalungun, sehingga mereka dapat merancang kebijakan yang terbaik dalam meningkatkan kualitas kesehatan masyarakat di daerah tersebut untuk masa yang akan datang. Penelitian ini juga memberikan kontribusi dalam pengembangan metode prediksi kesehatan berbasis kecerdasan buatan, khususnya untuk analisis persentase penduduk yang melakukan pengobatan sendiri dalam ruang lingkup regional yang kompleks dan dinamis.

Kata Kunci: Machine Learning; Kemandirian Kesehatan; Pengobatan Sendiri; Kota Pematangsiantar; Kabupaten Simalungun

Abstract—Self-medication is a practice in which individuals use drugs or administer treatments without a doctor's prescription or medical supervision. This phenomenon has become a significant health issue in Indonesia, particularly in the city of Pematangsiantar and Simalungun Regency, where many residents tend to self-medicate without receiving adequate medical consultation. Therefore, the aim of this study is to analyze the predicted percentage of health independence development among residents who self-medicate in Pematangsiantar and Simalungun Regency using the Levenberg-Marquardt algorithm. The research data consists of time-series data on the percentage of residents self-medicating in Pematangsiantar and Simalungun Regency from 2018 to 2023, obtained from the Central Statistics Agency of North Sumatra. The analysis was conducted using five architecture models: 4-5-1, 4-10-1, 4-15-1, 4-20-1, and 4-25-1. The results show that the Levenberg-Marquardt algorithm with the 4-15-1 architecture model provided the best performance, with the lowest Mean Squared Error (MSE) value of 0.0268691174 compared to the other architecture models. This study is expected to assist local governments by providing information on the development of the percentage of residents who self-medicate in Pematangsiantar and Simalungun Regency, enabling them to formulate the best policies for improving public health in the region in the future. This research also contributes to the development of artificial intelligence-based health prediction methods, particularly for analyzing the percentage of self-medicating residents in complex and dynamic regional contexts.

Keywords: Machine Learning; Health Independence; Self-Medication; Pematangsiantar City; Simalungun Regency

1. PENDAHULUAN

Pengobatan sendiri atau *self-medication* merupakan praktik di mana individu menggunakan obat-obatan atau melakukan pengobatan tanpa adanya resep dokter atau pengawasan medis [1]–[3]. Fenomena ini telah menjadi isu kesehatan yang penting di Indonesia [4], di mana banyak penduduk cenderung melakukan pengobatan sendiri tanpa memperoleh konsultasi medis yang memadai [5]. Pengobatan sendiri yang tidak tepat dapat berpotensi mengakibatkan risiko kesehatan yang serius [6], termasuk penggunaan obat yang tidak sesuai dosis, interaksi obat yang berbahaya, dan pengabaian terhadap kondisi medis yang mendasarinya. Pada saat yang sama, kemajuan teknologi dan ketersediaan data kesehatan yang mudah diperoleh memberikan peluang untuk menggunakan metode analisis data yang kompleks [7]–[9], seperti machine learning, untuk menggali wawasan baru dalam fenomena pengobatan sendiri. Machine learning merupakan teknologi yang mampu mengolah data dan menghasilkan prediksi berdasarkan pola-pola yang ditemukan dalam data [10]–[14], sehingga dapat digunakan untuk menganalisis perkembangan kemandirian kesehatan penduduk yang melakukan pengobatan sendiri dengan pendekatan yang lebih obyektif dan akurat. Oleh karena itu, penelitian ini diusulkan untuk mengaplikasikan pendekatan machine learning dengan algoritma prediksi dalam menganalisis perkembangan kemandirian kesehatan penduduk di kota Pematangsiantar dan kabupaten Simalungun yang melakukan pengobatan sendiri. Penelitian ini akan menggunakan data sekunder yang diperoleh dari Badan pusat Statistik

kota Pematangsiantar dan kabupaten Simalungun, yang diperoleh dari data survei kesehatan, data obat-obatan yang dijual bebas, serta data sosial ekonomi penduduk, untuk mengidentifikasi pola dan tren dalam pengobatan sendiri yang dilakukan oleh penduduk di daerah tersebut. Melalui penelitian ini, diharapkan dapat diperoleh pemahaman yang lebih komprehensif terhadap fenomena pengobatan sendiri di kalangan penduduk setempat, termasuk faktor-faktor yang mempengaruhi praktik pengobatan sendiri, serta risiko dan manfaat yang terkait. Temuan-temuan dari penelitian ini dapat digunakan sebagai dasar untuk merancang kebijakan dan intervensi yang tepat guna dalam meningkatkan kesadaran akan risiko dan manfaat pengobatan sendiri, serta mempromosikan praktik pengobatan yang aman dan efektif di kalangan penduduk di daerah tersebut. Selain itu, penggunaan pendekatan machine learning dan algoritma prediksi dalam penelitian ini diharapkan dapat memberikan kontribusi pada pengembangan metode analisis data dalam studi kesehatan dan menjadi acuan bagi penelitian lanjutan di bidang ini.

Pendekatan pemecahan masalah dalam penelitian ini adalah menggunakan pendekatan machine learning dengan algoritma prediksi *Levenberg-Marquardt*. Penelitian akan menggunakan data sekunder yang telah ada, untuk melatih dan menguji model machine learning yang akan digunakan untuk menganalisis perkembangan kemandirian kesehatan penduduk kota Pematangsiantar dan kabupaten Simalungun yang melakukan pengobatan sendiri. Algoritma prediksi akan digunakan untuk memprediksi kemungkinan perkembangan kemandirian kesehatan di masa depan. *Levenberg-Marquardt* adalah metode optimasi non-linier yang digunakan untuk menyelesaikan masalah fitting kurva, khususnya dalam konteks regresi non-linier. Algoritma ini menggabungkan pendekatan Gauss-Newton dan gradient descent untuk menemukan nilai parameter yang meminimalkan kesalahan antara prediksi model dan data observasi. Algoritma ini menawarkan keseimbangan yang baik antara kecepatan dan akurasi dalam menemukan solusi optimal dan menjadikannya pilihan populer dalam penyelesaian masalah prediksi.

Penelitian-penelitian terdahulu terkait tema penelitian ini, diantaranya: Penelitian untuk memprediksi efek samping obat yang tidak diketahui jumlahnya, yang diidentifikasi secara acak dalam uji klinis terkontrol dengan menggunakan kerangka kerja *machine learning* Geometric Self-Expressive Model (GSEM). Penelitian menunjukkan kegunaan GSEM pada 505 obat yang beragam secara terapeutik dan 904 efek samping dari berbagai sistem fisiologis manusia [15]. Penelitian dengan menggunakan model machine learning untuk memprediksi krisis kesehatan mental dari catatan kesehatan elektronik. Penelitian ini menguji berbagai teknik machine learning, seperti: *including decision trees, probabilistic, ensembles, deep learning-based classifiers* dan *XGBoost (eXtreme Gradient Boosting)*. Hasil evaluasi menunjukkan *XGBoost* mengungguli metode lain meskipun hanya dengan margin kecil. Walaupun demikian teknik ini dapat digunakan untuk memprediksi pasien yang berisiko mengalami krisis kesehatan mental [16]. Penelitian berikutnya menerapkan machine learning untuk tantangan dan peluang layanan kesehatan. Pada penelitian ini machine learning dapat diterapkan untuk memprediksi data berlabel berdasarkan algoritma seperti: *logistic regression, support vector machine, decision tree, LASSO regression, K Nearest Neighbor*, dan *Naive Bayes classifier*. Hasilnya algoritma machine learning tersebut mampu merumuskan beberapa sistem pendukung keputusan klinis dan memprediksi parameter kesehatan berbasis populasi [17]. Penelitian selanjutnya dilakukan untuk mengatasi ketidakpastian prediksi pada machine learning untuk layanan kesehatan. Untuk mencegah kegagalan prediksi yang tidak aman dari model machine learning, pengguna sistem harus menyadari keakuratan model umum dan memahami tingkat kepercayaan pada setiap prediksi individu. Hasil dari penelitian ini bahwa otomatisasi dengan mendukung machine learning dapat berdampak besar pada layanan kesehatan [18]. Penelitian berikutnya memanfaatkan machine learning dan kecerdasan buatan dalam penelitian dan perawatan kesehatan Electronic Medical Records/EMR (Rekam Medis Elektronik) pasien. Pertimbangan penggunaan dan penerapan machine learning di lingkungan layanan kesehatan mencakup transparansi, interpretasi, dan etika. Hasil penelitian ini menerangkan bahwa penerapan machine learning saat ini dan di masa depan mencakup peningkatan kualitas dan kuantitas data kesehatan dapat lebih transparan dalam pengambilan keputusan klinis [19]. Selanjutnya penelitian untuk memprediksi Tromboemboli Vena/*Venous Thromboembolism* (VTE) pada berbagai populasi menggunakan machine learning dan catatan kesehatan elektronik terstruktur. Penelitian ini melatih dan memvalidasi model data dari 159.001 peserta di Gudang Data Mount Sinai, kemudian mengujinya secara eksternal pada 401.723 peserta di UK Biobank dan 123.039 peserta di All of Us. Semua kumpulan data berisi populasi dari beragam riwayat klinis. Kumpulan data ini digunakan untuk mengembangkan model kecil, menengah, dan besar dengan peningkatan fitur pada berbagai pengoptimalan portabilitas untuk memperoleh kinerja yang maksimal. Hasil penelitian menjelaskan bahwa machine learning dengan metode *LightGBM* mampu secara signifikan meningkatkan diagnosis VTE dan prediksi risiko 1 tahun pada beragam populasi, mengungguli model *logistic regression, random forest*, dan *XGBoost* [20]. Masih banyak lagi penelitian-penelitian lainnya [21]–[23], yang mendasari dilakukannya penelitian ini, karena kemampuan dari algoritma machine learning dalam menyelesaikan masalah terkait peramalan atau prediksi. Oleh sebab itu penelitian yang diusulkan akan memanfaatkan machine learning juga, untuk menyelesaikan masalah terkait prediksi data kesehatan, tentu nya dengan algoritma dan dataset penelitian yang berbeda.

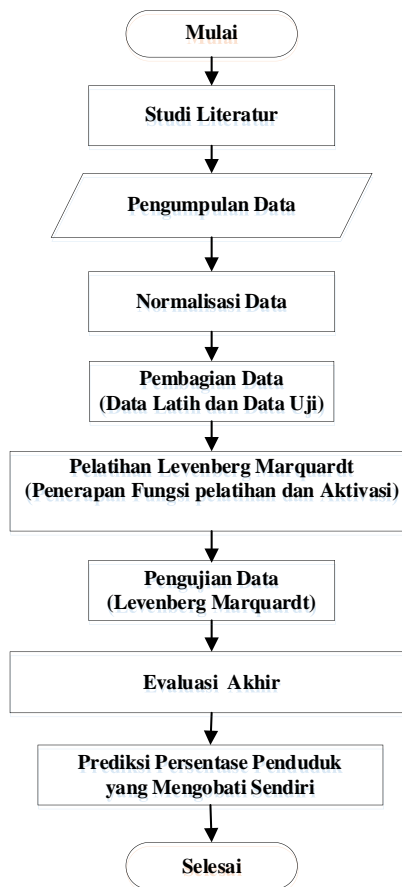
Berdasarkan latar belakang yang telah diuraikan, maka Kebaruan penelitian ini terletak pada pendekatan machine learning dengan algoritma prediksi *Levenberg-Marquardt* untuk menganalisis perkembangan kemandirian kesehatan penduduk di Pematangsiantar dan Simalungun yang melakukan pengobatan sendiri.

Penelitian dengan topik kesehatan masyarakat, khususnya dalam pengobatan sendiri, masih tergolong baru dan belum banyak diteliti. Penelitian ini akan memberikan kontribusi baru dalam menggali informasi yang mendalam dan objektif tentang praktik pengobatan sendiri di kalangan penduduk. Selain itu, penggunaan algoritma prediksi pada analisis data dapat memberikan kebaruan dalam memprediksi kemungkinan perkembangan kemandirian kesehatan di masa depan, yang dapat digunakan sebagai dasar untuk merancang intervensi yang lebih efektif dalam meningkatkan kesadaran akan risiko dan manfaat pengobatan sendiri. Oleh karena itu, penelitian ini diharapkan dapat memberikan sumbangan original dan berpotensi untuk mengisi celah pengetahuan dalam bidang ini.

2. METODOLOGI PENELITIAN

2.1 Flowchart atau Tahapan Penelitian

Flowchart atau tahapan pada penelitian ini merupakan representasi visual yang menunjukkan langkah-langkah sistematis yang harus diikuti dalam proses penelitian. Tahapan ini memberikan gambaran yang jelas tentang alur penelitian dari awal hingga akhir, yang langkah-langkahnya dapat dilihat pada Gambar 1 berikut ini.



Gambar 1. Flowchart atau Tahapan Penelitian

Untuk mencapai tujuan penelitian, diperlukan pendekatan sistematis yang mencakup langkah-langkah utama dalam pengolahan data dan analisis. Penelitian ini dilaksanakan melalui serangkaian tahapan yang dirancang untuk memastikan keakuratan dan keandalan hasil prediksi persentase penduduk yang melakukan pengobatan sendiri. Tahapan tersebut dapat dijelaskan sebagai berikut:

a. Studi Literatur

Mengumpulkan dan menelaah literatur, artikel, jurnal, buku, dan sumber-sumber informasi lain yang berkaitan dengan topik penelitian.

b. Pengumpulan Data

Tahapan yang dilakukan pada bagian ini adalah mengumpulkan data Persentase Penduduk di kota Pematangsiantar dan kabupaten Simalungun yang melakukan pengobatan sendiri tahun 2018-2023. Data tersebut akan digunakan sebagai dataset penelitian.

c. Normalisasi Data

Dataset penelitian akan di normalisasi terlebih dahulu menggunakan rumus normalisasi berdasarkan persamaan (1) [24]–[26].

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

Dimana x' merupakan hasil dari proses normalisasi, x merupakan data yang akan dinormalisasi, a merupakan data terkecil dari data penelitian, b merupakan data terbesar dari data penelitian, sedangkan 0.8 dan 0.1 merupakan nilai default untuk proses normalisasi

d. Pembagian Data (Data Latih dan data Uji)

Data pelatihan dan pengujian merujuk pada dua jenis data yang digunakan dalam proses pengembangan dan evaluasi model arsitektur menggunakan algoritma *Levenberg-Marquardt*. Data pelatihan digunakan untuk melatih model arsitektur. Data ini digunakan untuk mengajarkan model bagaimana harus melakukan prediksi. Sedangkan data pengujian merupakan data yang digunakan untuk menguji kinerja model arsitektur setelah proses pelatihan selesai. Data ini digunakan untuk mengukur seberapa baik model arsitektur dapat melakukan prediksi.

e. Pelatihan *Levenberg-Marquardt* (Penerapan Fungsi Pelatihan dan Aktivasi)

Tahap ini merupakan proses di mana model arsitektur awal dibangun menggunakan algoritma *Levenberg-Marquardt*, kemudian diberikan input data pelatihan untuk mempelajari pola-pola yang ada dalam data tersebut. Salah satu aspek penting dalam pelatihan machine learning adalah pemilihan fungsi pelatihan atau fungsi aktivasi yang digunakan untuk mengoptimalkan bobot dan bias.

f. Pengujian Data (*Levenberg-Marquardt*)

Tahapan ini dilakukan untuk memastikan bahwa model arsitektur yang telah dilatih dengan data pelatihan mampu melakukan generalisasi dan bekerja dengan baik. Pengujian data juga dilakukan dengan menggunakan algoritma *Levenberg-Marquardt*.

g. Evaluasi Akhir

Bagian ini merupakan tahap pemilihan model arsitektur terbaik berdasarkan analisis dari 5 model yang dibandingkan, setelah melalui tahap pelatihan, dan pengujian.

h. Prediksi Persentase Penduduk yang Mengobati Sendiri

Tahap terakhir dalam penelitian ini adalah melakukan prediksi persentase perkembangan kemandirian kesehatan penduduk yang melakukan pengobatan sendiri di kota Pematangsiantar dan kabupaten Simalungun menggunakan model arsitektur terbaik dari algoritma *Levenberg-Marquardt*.

Nilai Prediksi diperoleh dengan menggunakan algoritma terbaik dan berdasarkan model terbaik pula. Rumus perhitungannya diperoleh dengan membalikkan rumus persamaan (1) yang sudah dijelaskan sebelumnya [27]–[29].

$$\text{Prediksi} = \frac{(x-0,1)(b-a)}{0,8} + a \tag{2}$$

Dimana x merupakan Target prediksi, a merupakan Data terendah, b merupakan Data tertinggi, sedangkan nilai 0.1 dan 0.8 merupakan Nilai default untuk melakukan prediksi.

2.2 Metode *Levenberg-Marquardt*

Teknik ini merupakan fungsi pelatihan jaringan yang memperbaiki bobot dan nilai bias sesuai dengan optimasi *Levenberg-Marquardt*. Selain itu teknik *Levenberg-Marquardt* seringkali merupakan algoritma tercepat di *toolbox* Matlab, dan sangat direkomendasikan sebagai algoritma pengawasan pilihan pertama, meskipun membutuhkan lebih banyak memori daripada algoritma lain [30]. Teknik *Levenberg-Marquardt* dapat dirumuskan sebagai berikut:

$$net, TR] = \text{trainlm}(net, TR, \text{trainV}, \text{valV}, \text{testV}) \tag{3}$$

Dimana : *net* merupakan Pembentukan Jaringan. *TR* merupakan Catatan pelatihan awal yang dibuat berdasarkan data latih di setiap epoch (iterasi). *Trainlm* merupakan Fungsi pelatihan *Levenberg-Marquardt*. *trainV* merupakan Data pelatihan yang dibuat berdasarkan data latih. *valV* merupakan Data validasi yang dibuat berdasarkan data latih. Sedangkan *testV* merupakan Data uji yang dibuat berdasarkan data latih.

2.3 Pengumpulan Data

Data penelitian ini berupa dataset *times-series* persentase penduduk yang melakukan pengobatan sendiri di kota Pematangsiantar dan kabupaten Simalungun tahun 2018-2023. Pengumpulan data dilakukan pada Badan Pusat Statistik (BPS) Sumatera Utara. Informasi lengkapnya dapat dilihat pada Tabel 1 berikut ini.

Tabel 1. Persentase Penduduk Pematangsiantar dan Simalungun yang Melakukan Pengobatan Sendiri

No	Kabupaten / Kota	Persentase Penduduk yang Melakukan Pengobatan Sendiri					
		2018	2019	2020	2021	2022	2023
A	Kabupaten Simalungun	54,34	62,77	51,34	75,15	80,36	75,10
B	Kota Pematangsiantar	76,02	67,83	82,52	78,38	69,51	70,82

Berdasarkan data yang disajikan pada Tabel 1, persentase penduduk di kota Pematangsiantar dan kabupaten Simalungun yang melakukan pengobatan sendiri, nilai nya fluktuatif. Pada tahun 2019, persentase penduduk yang melakukan pengobatan sendiri di kabupaten Simalungun mengalami kenaikan sebesar 8,3% dibandingkan tahun 2018. Pada tahun 2020 turun cukup tajam menjadi 51,34% atau sebesar 11,43%. Mengalami kenaikan lagi sebesar 23,81% di tahun 2021, naik kembali di tahun 2022 sebesar 5,21%, dan mengalami penurunan kembali di tahun 2023 sebesar 5,26%. Sehingga nilai persentase di akhir di tahun 2023 sebesar 75,10%. Sedangkan di kota Pematangsiantar, pada tahun 2019 persentase nya mengalami penurunan sebesar 8,19% dibandingkan nilai awal tahun 2018 sebesar 76,02%. Pada tahun 2020 naik cukup signifikan menjadi 82,52% atau meningkat 14,69% dibandingkan tahun 2019. Pada tahun 2021 turun sebesar 4,14%, dan turun kembali di tahun 2022 sebesar 8,87%, dan meningkat kembali di tahun 2023 sebesar 1,31%. Sehingga nilai persentase penduduk di kota Pematangsiantar yang melakukan pengobatan sendiri sebesar 70,82%.

Tingginya persentase penduduk yang melakukan pengobatan sendiri tidak selalu menjadi indikator yang baik bagi suatu daerah. Tingginya angka pengobatan sendiri bisa menandakan bahwa banyak penduduk tidak memiliki akses yang memadai ke fasilitas kesehatan, dokter, atau obat-obatan yang diresepkan. Hal ini bisa menjadi masalah, terutama jika pengobatan yang dilakukan tidak tepat atau tidak diawasi. Pengobatan sendiri sering kali berisiko menyebabkan salah diagnosis atau penggunaan obat yang tidak sesuai. Pada sisi lain, jika pengobatan sendiri dilakukan dengan benar, bisa menunjukkan peningkatan kemandirian kesehatan, di mana penduduk memiliki pemahaman yang baik tentang kesehatan mereka dan mampu menangani masalah kesehatan ringan secara mandiri. Namun, ini tetap harus didukung dengan edukasi yang tepat. Idealnya, tingginya kemandirian kesehatan harus didukung oleh sistem kesehatan yang kuat, di mana penduduk dapat dengan mudah mendapatkan informasi yang benar tentang obat-obatan dan kesehatan.

3. HASIL DAN PEMBAHASAN

3.1 Normalisasi dan Pembagian Data (Data Latih dan Data Uji)

Pada tahapan ini, data yang telah disajikan di Tabel 1 akan di normalisasi menggunakan persamaan (1), dan kemudian dibagi menjadi dua bagian (data latih dan data uji). Data tahun 2018 (D1) - 2021 (D4) akan digunakan sebagai input data latih, dan data tahun 2022 (T1) digunakan sebagai target (*output*) data latih. Sedangkan Data tahun 2019 (D5) - 2022 (D8) akan digunakan sebagai input data uji, dan data tahun 2023 (T2) digunakan sebagai target (*output*) data uji. Hasil normalisasi dan pembagian data dapat dilihat pada Tabel 2 dan 3 berikut ini.

Tabel 2. Hasil Normalisasi dan Pembagian Data Latih

Data	D1	D2	D3	D4	Target (T1)
A	0,17697	0,39326	0,10000	0,71090	0,84458
B	0,73323	0,52309	0,90000	0,79378	0,56620

Tabel 2 menunjukkan hasil normalisasi dan pembagian data latih. Kolom "Data" menunjukkan identitas data yang digunakan, sedangkan kolom "D1, D2, D3, D4" menunjukkan fitur atau variabel yang telah dinormalisasi menjadi nilai antara 0 dan 1. Kolom "Target (T1)" menunjukkan nilai target atau output yang diharapkan dari data, juga telah di normalisasi.

Tabel 3. Hasil Normalisasi dan Pembagian Data Uji

Data	D5	D6	D7	D8	Target (T2)
A	0,39326	0,10000	0,71090	0,84458	0,70962
B	0,52309	0,90000	0,79378	0,56620	0,59981

Tabel 3 menunjukkan hasil normalisasi dan pembagian data uji, yang merupakan bagian kedua dari proses analisis data setelah data latih. Kolom "Data" menunjukkan identitas data yang digunakan, sedangkan kolom "D5, D6, D7, D8" menunjukkan fitur atau variabel yang telah dinormalisasi menjadi nilai antara 0 dan 1. Kolom "Target (T2)" menunjukkan nilai target atau output yang diharapkan dari data, juga telah di normalisasi.

3.2 Pelatihan *Levenberg-Marquardt* (Penerapan Fungsi Pelatihan dan Aktivasi)

Setelah tahapan normalisasi dan pembagian data selesai dilakukan, selanjutnya adalah melakukan analisis algoritma *Levenberg-Marquardt* dengan model arsitektur jaringan yang akan digunakan (4-5-1, 4-10-1, 4-15-1, 4-20-1 dan 4-25-1), dan melatihnya dengan bantuan *tools* Matlab R2011b. Fungsi pelatihan yang digunakan adalah *trainlm*, sedangkan fungsi aktivasi yang digunakan untuk pelatihan adalah *tansig* dan *logsig*.

3.2.1 Model Arsitektur Jaringan 4-5-1

Hasil pelatihan menggunakan model arsitektur 4-5-1 dapat dilihat pada Tabel 4. Hasil pelatihan dengan menggunakan model arsitektur ini menghasilkan output yang sama dengan target, dengan kata lain proses pelatihan dengan algoritma *Levenberg-Marquardt* sangat baik karena tingkat kesalahannya 0.

Tabel 4. Hasil Pelatihan Model Arsitektur 4-5-1

Data	Target	Output	Error	SSE
A	0,84458	0,84460	-0,00002	0,00000000041
B	0,56620	0,56620	0,00000	0,00000000001
Jumlah SSE				0,00000000042
MSE				0,00000000021

Keterangan: Data A merupakan data Kabupaten Simalungun, sedangkan data B merupakan data Kota Pematangsiantar. Nilai Target diperoleh dari Target (T1) pada Tabel 2. Sedangkan Output diperoleh dari proses pelatihan dengan menggunakan aplikasi Matlab R2011b. Nilai Error diperoleh dari Target-Output. Nilai SSE diperoleh dari $Error^2$. Jumlah SSE diperoleh dari penjumlahan SSE. Sedangkan MSE diperoleh dari Jumlah SSE / 2 (banyak nya data).

3.2.2 Model Arsitektur Jaringan 4-10-1, 4-15-1, 4-20-1, dan 4-25-1

Hasil pelatihan berikutnya, yakni pelatihan dengan model arsitektur 4-10-1, 4-15-1, 4-20-1, dan 4-25-1. Hasil nya model arsitektur 4-10-1, 4-20-1, dan 4-25-1 memperoleh nilai yang sama dengan hasil pelatihan pada model arsitektur 4-5-1 yang terdapat pada Tabel 4, dengan Jumlah SSE sebesar 0,00000000042 dan nilai MSE sebesar 0,00000000021. Hanya model arsitektur 4-15-1 yang berbeda dibandingkan 4 model arsitektur yang lain. Hasil pelatihan menggunakan model arsitektur 4-15-1 dapat dilihat pada Tabel 5.

Tabel 5. Hasil Pelatihan Model Arsitektur 4-5-1

Target	Output	Error	SSE
0,84458	0,84460	-0,00002	0,00000000041
0,56620	0,56620	0,00000	0,00000000001
Jumlah SSE			0,00000000042
MSE			0,00000000002

Berdasarkan analisis dari seluruh pelatihan yang telah dilakukan terhadap masing-masing model arsitektur, ternyata 4 model arsitektur (4-5-1, 4-10-1, 4-20-1, dan 4-25-1) memiliki kemampuan yang sama, hanya model arsitektur 4-15-1 yang berbeda.

3.3 Pengujian Data

Langkah selanjutnya adalah melakukan pengujian data terhadap masing-masing model arsitektur yang digunakan (4-5-1, 4-10-1, 4-15-1, 4-20-1, dan 4-25-1), analisis ini dilakukan untuk melihat dan mencari model arsitektur yang terbaik yang akan digunakan untuk melakukan prediksi data.

3.3.1 Model Arsitektur Jaringan 4-5-1

Hasil pengujian algoritma *Levenberg-Marquardt* dengan model arsitektur 4-5-1 dapat dilihat pada Tabel 6. Berdasarkan hasil pengujian, diperoleh Jumlah SSE sebesar 0,39095866325 dan nilai MSE sebesar 0,19547933163.

Tabel 6. Hasil Pengujian Model Arsitektur 4-5-1

Data	Target	Output	Error	SSE
A	0,70962	0,18500	0,52462	0,27522777311
B	0,59981	0,94000	-0,34019	0,11573089014
Jumlah SSE				0,39095866325
MSE				0,19547933163

Berdasarkan perbandingan antara hasil pelatihan dan hasil pengujian, terdapat perbedaan yang cukup jauh antara nilai SSE, Jumlah SSE, dan nilai MSE. Tetapi hal ini wajar, dengan syarat nilai SSE, Jumlah SSE, dan nilai MSE masih dalam batas 0. Karena salah satu tujuannya analisis ini adalah untuk mencari model arsitektur yang memiliki nilai kesalahan (MSE) paling kecil dari 5 model arsitektur yang di akan diuji.

3.3.2 Model Arsitektur Jaringan 4-10-1

Hasil pengujian algoritma *Levenberg-Marquardt* dengan model arsitektur 4-10-1 dapat dilihat pada Tabel 7. Berdasarkan hasil pengujian, diperoleh Jumlah SSE sebesar 0,35248183051 dan nilai MSE sebesar 0,17624091525.

Tabel 7. Hasil Pengujian Model Arsitektur 4-10-1

Data	Target	Output	Error	SSE
A	0,70962	0,16140	0,54822	0,30054687038
B	0,59981	0,82770	-0,22789	0,05193496013

Data	Target	Output	Error	SSE
			Jumlah SSE	0,35248183051
			MSE	0,17624091525

3.3.3 Model Arsitektur Jaringan 4-15-1

Hasil pengujian algoritma *Levenberg-Marquardt* dengan model arsitektur 4-15-1 dapat dilihat pada Tabel 8. Berdasarkan hasil pengujian, diperoleh Jumlah SSE sebesar 0,05373823484 dan nilai MSE sebesar 0,02686911742.

Tabel 8. Hasil Pengujian Model Arsitektur 4-15-1

Data	Target	Output	Error	SSE
A	0,70962	0,90270	-0,19308	0,03727928698
B	0,59981	0,72810	-0,12829	0,01645894786
			Jumlah SSE	0,05373823484
			MSE	0,02686911742

3.3.4 Model Arsitektur Jaringan 4-20-1

Hasil pengujian algoritma *Levenberg-Marquardt* dengan model arsitektur 4-20-1 dapat dilihat pada Tabel 9. Berdasarkan hasil pengujian, diperoleh Jumlah SSE sebesar 0,17016977649 dan nilai MSE sebesar 0,08508488825.

Tabel 9. Hasil Pengujian Model Arsitektur 4-20-1

Data	Target	Output	Error	SSE
A	0,70962	0,87410	-0,16448	0,02705315977
B	0,59981	0,22150	0,37831	0,14311661673
			Jumlah SSE	0,17016977649
			MSE	0,08508488825

3.3.5 Model Arsitektur Jaringan 4-25-1

Hasil pengujian algoritma *Levenberg-Marquardt* dengan model arsitektur 4-25-1 dapat dilihat pada Tabel 10. Berdasarkan hasil pengujian, diperoleh Jumlah SSE sebesar 0,38648239433 dan nilai MSE sebesar 0,19324119717.

Tabel 10. Hasil Pengujian Model Arsitektur 4-5-1

Data	Target	Output	Error	SSE
A	0,70962	0,12470	0,58492	0,34213322232
B	0,59981	0,81040	-0,21059	0,04434917201
			Jumlah SSE	0,38648239433
			MSE	0,19324119717

3.4 Evaluasi Akhir


Langkah yang akan dilakukan selanjutnya setelah proses pelatihan dan pengujian pada seluruh model arsitektur yang digunakan selesai dilakukan adalah melakukan Evaluasi akhir. Tahapan ini untuk melihat *Performance* (kemampuan) masing-masing model arsitektur. Pengujian Algoritma *Levenberg-Marquardt* dengan masing-masing model arsitektur yang memiliki tingkat kesalahan terendah (terkecil), akan dipilih sebagai model arsitektur terbaik yang selanjutnya akan digunakan untuk memprediksi persentase penduduk di Kota Pematangsiantar dan Kabupaten Simalungun yang melakukan pengobatan sendiri.

Berdasarkan analisis dari masing-masing model arsitektur yang telah dilatih dan diuji menggunakan algoritma *Levenberg-Marquardt*, memperoleh hasil terbaik pada model 4-15-1, dengan nilai MSE (kesalahan) sebesar 0,02686911742. Perbandingan hasil data pelatihan dari masing-masing model arsitektur yang digunakan dapat dilihat pada Tabel 11.

Tabel 11. Perbandingan Model Arsitektur dengan Algoritma *Levenberg-Marquardt*

Model Arsitektur	Iterasi	Fungsi Aktivasi	MSE Pelatihan	MSE Pengujian
4-5-1	6		0,00000000021	0,19547933163
4-10-1	5		0,00000000021	0,17624091525
4-15-1	5	tansig, logsig	0,00000000002	0,02686911742
4-20-1	4		0,00000000021	0,08508488825
4-25-1	5		0,00000000021	0,19324119717

Tabel 11 menunjukkan perbandingan hasil pelatihan dan pengujian beberapa model arsitektur jaringan saraf tiruan (JST) dengan algoritma Levenberg-Marquardt. Kolom "Model Arsitektur" menunjukkan konfigurasi lapisan input, lapisan tersembunyi, dan lapisan output pada JST, sedangkan kolom "Iterasi" menunjukkan jumlah iterasi yang diperlukan untuk mencapai konvergensi. Kolom "Fungsi Aktivasi" menunjukkan jenis fungsi aktivasi yang digunakan pada lapisan tersembunyi, tetapi hanya model 4-15-1 yang menunjukkan nilai ini. Kolom "MSE Pelatihan" dan "MSE Pengujian" menunjukkan nilai Mean Squared Error (MSE) pada data pelatihan dan pengujian, yang menunjukkan seberapa baik model tersebut dapat memprediksi nilai target. Hasil ini menunjukkan bahwa model 4-15-1 memiliki nilai MSE pengujian yang paling rendah, sehingga dapat dianggap sebagai model yang paling baik.



Gambar 2. Perbandingan Performance (MSE Pengujian)

Berdasarkan Gambar 2, terlihat jelas perbandingan hasil dari 5 model arsitektur yang digunakan dalam penelitian ini. Evaluasi akhir diperoleh bahwa algoritma *Levenberg-Marquardt* dengan model arsitektur 4-15-1 terpilih sebagai model terbaik, yang nanti nya akan digunakan sebagai pedoman untuk melakukan prediksi. MSE menghitung rata-rata dari kuadrat selisih antara nilai yang sebenarnya (observasi) dan nilai yang diprediksi. Semakin kecil nilai MSE, semakin baik model dalam memprediksi data karena kesalahan prediksinya lebih rendah.

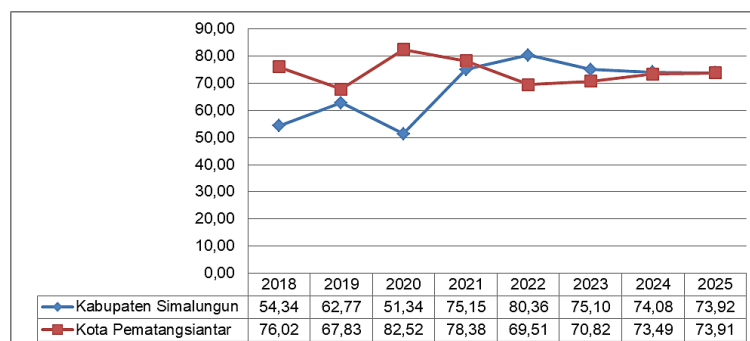
3.5 Prediksi Persentase Penduduk yang Mengobati Sendiri

Nilai Prediksi diperoleh dengan menggunakan algoritma *Levenberg-Marquardt* berdasarkan model terbaik 4-15-1. Rumus perhitungannya diperoleh dengan menggunakan rumus persamaan (2) yang sudah dijelaskan sebelumnya. Hasil prediksi dapat dilihat pada Tabel 12 berikut ini.

Tabel 12. Prediksi Persentase Penduduk Pematangsiantar dan Simalungun yang Melakukan Pengobatan Sendiri

No	Kabupaten / Kota	Persentase Penduduk yang Melakukan Pengobatan Sendiri						Prediksi	
		2018	2019	2020	2021	2022	2023	2024	2025
A	Kabupaten Simalungun	54,34	62,77	51,34	75,15	80,36	75,10	74,08	73,92
B	Kota Pematangsiantar	76,02	67,83	82,52	78,38	69,51	70,82	73,49	73,91

Tabel 12 menunjukkan prediksi persentase penduduk yang melakukan pengobatan sendiri di Kabupaten Simalungun dan Kota Pematangsiantar dari tahun 2018 hingga 2025. Persentase tersebut menunjukkan tren yang berbeda-beda antara kedua daerah tersebut, dengan Kabupaten Simalungun mengalami peningkatan dan penurunan yang signifikan, sedangkan Kota Pematangsiantar menunjukkan pola yang lebih stabil.



Gambar 3. Grafik Persentase Penduduk yang Melakukan Pengobatan Sendiri

Gambar 3 menyajikan perbandingan dari data persentase penduduk yang melakukan pengobatan sendiri di Kota Pematangsiantar dan Kabupaten Simalungun sebelum nya di tahun 2018 hingga 2023, dengan data hasil prediksi 2 tahun yang akan datang, yakni tahun 2024 dan 2025. Berdasarkan data yang disajikan pada Tabel 12 dan Grafik pada Gambar 3, di prediksi nilai persentase penduduk yang melakukan pengobatan sendiri tahun 2024 dan 2025 di Kota Pematangsiantar akan mengalami kenaikan, sedangkan di Kabupaten Simalungun diperkirakan akan menurun, walaupun nilai nya tidak terlalu signifikan.

4. KESIMPULAN

Penelitian ini memanfaatkan algoritma machine learning *Levenberg-Marquardt* untuk menganalisis dan memprediksi persentase penduduk yang melakukan pengobatan sendiri di Kota Pematangsiantar dan Kabupaten Simalungun. Beberapa model arsitektur jaringan syaraf tiruan (JST) diuji, termasuk arsitektur 4-5-1, 4-10-1, 4-15-1, 4-20-1, dan 4-25-1. Berdasarkan hasil analisis, model 4-15-1 dipilih sebagai model terbaik karena memiliki nilai Mean Squared Error (MSE) paling rendah, yaitu 0,0268691174, dibandingkan dengan arsitektur lainnya. Hal ini menunjukkan bahwa model 4-15-1 memberikan prediksi yang lebih akurat dibandingkan model lain yang diuji dalam penelitian ini. Berdasarkan prediksi untuk tahun 2024 dan 2025, hasil penelitian menunjukkan bahwa persentase penduduk yang melakukan pengobatan sendiri di Kota Pematangsiantar diperkirakan akan mengalami peningkatan. Sementara itu, di Kabupaten Simalungun, tren persentase penduduk yang melakukan pengobatan sendiri diprediksi mengalami penurunan meskipun tidak terlalu signifikan dibandingkan dengan data pada tahun 2023. Meskipun hasil penelitian ini memberikan gambaran yang cukup jelas mengenai tren pengobatan sendiri di kedua daerah, terdapat beberapa keterbatasan yang perlu diperhatikan. Salah satu keterbatasan utama adalah penggunaan data yang terbatas pada periode waktu tertentu serta variabel yang digunakan mungkin belum mencakup faktor-faktor lain yang dapat memengaruhi tren pengobatan sendiri, seperti akses terhadap fasilitas kesehatan atau perubahan kebijakan kesehatan. Pada penelitian selanjutnya, disarankan agar cakupan data diperluas dan variabel tambahan yang relevan dimasukkan guna menghasilkan prediksi yang lebih akurat serta memahami lebih dalam faktor-faktor yang memengaruhi perilaku pengobatan sendiri di masyarakat.

REFERENCES

- [1] A. Quincho-lopez, C. A. Benites-Ibarra, M. M. Hilario-Gomez, R. Quijano-Escate, dan A. Taype-Rondan, "Self-medication practices to prevent or manage COVID-19 : A systematic review," *PLOS ONE*, vol. 16, no. 11, hal. 1–12, 2021, doi: 10.1371/journal.pone.0259317.
- [2] D. Baracaldo-Santamaría, M. J. Trujillo-Moreno, A. M. Pérez-Acosta, J. E. Feliciano-Alfonso, C. A. Calderon-Ospina, dan F. Soler, "Definition of self-medication: a scoping review," *Therapeutic Advances in Drug Safety*, vol. 13, hal. 1–14, 2022, doi: 10.1177/20420986221127501.
- [3] I. Ahmed, R. King, S. Akter, R. Akter, dan V. R. Aggarwal, "Determinants of antibiotic self-medication: A systematic review and meta-analysis," *Research in Social and Administrative Pharmacy*, vol. 19, no. 7, hal. 1007–1017, 2023, doi: 10.1016/j.sapharm.2023.03.009.
- [4] N. Ahmed, S. Ijaz, S. Manzoor, dan S. Sajjad, "Prevalence of self-medication in children under-five years by their mothers in Yogyakarta city Indonesia," *Journal of Family Medicine and Primary Care*, vol. 10, no. 8, hal. 2798–2803, 2021, doi: 10.4103/jfmpc.jfmpc_2457_20.
- [5] P. Ge dkk., "Self-medication in Chinese residents and the related factors of whether or not they would take suggestions from medical staff as an important consideration during self-medication," *Frontiers in Public Health*, vol. 10, hal. 1–18, 2022, doi: 10.3389/fpubh.2022.1074559.
- [6] A. Carias, K. Orellana, W. Cruz, F. Rodriguez Rivas, D. Naira, dan P. Simons Morales, "Automedicación en pacientes mayores de 18 años en centros de salud de Honduras," *Journal of Pharmacy & Pharmacognosy Research*, vol. 10, no. 2, hal. 218–226, 2022, doi: 10.56499/jppres21.1148_10.2.218.
- [7] M. Karatas, L. Eriskin, M. Deveci, D. Pamucar, dan H. Garg, "Big Data for Healthcare Industry 4.0: Applications, challenges and future perspectives," *Expert Systems with Applications*, vol. 200, hal. 116912, 2022, doi: 10.1016/j.eswa.2022.116912.
- [8] M. Senbekov dkk., "The recent progress and applications of digital technologies in healthcare: A review," *International Journal of Telemedicine and Applications*, vol. 2020, hal. 1–18, 2020, doi: 10.1155/2020/8830200.
- [9] J. P. Onnela, "Opportunities and challenges in the collection and analysis of digital phenotyping data," *Neuropsychopharmacology*, vol. 46, no. 1, hal. 45–54, 2021, doi: 10.1038/s41386-020-0771-3.
- [10] S. Singh, P. Bansal, M. Hosen, dan S. K. Bansal, "Forecasting annual natural gas consumption in USA: Application of machine learning techniques- ANN and SVM," *Resources Policy*, vol. 80, no. 1, hal. 103159, 2023, doi: 10.1016/j.resourpol.2022.103159.
- [11] H. Dichtl, W. Drobetz, dan T. Otto, "Forecasting Stock Market Crashes via Machine Learning," *Journal of Financial Stability*, vol. 65, no. 1, hal. 101099, 2023, doi: 10.1016/j.jfs.2022.101099.
- [12] B. A. Aderemi, T. O. Olwal, J. M. Ndambuki, dan S. S. Rwanga, "Groundwater levels forecasting using machine learning models: A case study of the groundwater region 10 at Karst Belt, South Africa," *Systems*

- and Soft Computing*, vol. 5, no. 1, hal. 200049, 2023, doi: 10.1016/j.sasc.2023.200049.
- [13] M. Akbarian, B. Saghafian, dan S. Golian, "Monthly streamflow forecasting by machine learning methods using dynamic weather prediction model outputs over Iran," *Journal of Hydrology*, vol. 1, no. April, hal. 129480, 2023, doi: 10.1016/j.jhydrol.2023.129480.
- [14] R. Rakholia, Q. Le, B. Quoc Ho, K. Vu, dan R. Simon Carbajo, "Multi-output machine learning model for regional air pollution forecasting in Ho Chi Minh City, Vietnam," *Environment International*, vol. 173, no. January, hal. 107848, 2023, doi: 10.1016/j.envint.2023.107848.
- [15] D. Galeano dan A. Paccanaro, "Machine learning prediction of side effects for drugs in clinical trials," *Cell Reports Methods*, vol. 2, no. 12, hal. 100358, 2022, doi: 10.1016/j.crmeth.2022.100358.
- [16] R. Garriga dkk., "Machine learning model to predict mental health crises from electronic health records," *Nature Medicine*, vol. 28, no. 6, hal. 1240–1248, 2022, doi: 10.1038/s41591-022-01811-5.
- [17] A. Alanazi, "Using machine learning for healthcare challenges and opportunities," *Informatics in Medicine Unlocked*, vol. 30, no. March, hal. 100924, 2022, doi: 10.1016/j.imu.2022.100924.
- [18] M. Chua dkk., "Tackling prediction uncertainty in machine learning for healthcare," *Nature Biomedical Engineering*, vol. 7, hal. 711–718, 2023, doi: 10.1038/s41551-022-00988-x.
- [19] L. Rubinger, A. Gazendam, S. Ekhtiari, dan M. Bhandari, "Machine learning and artificial intelligence in research and healthcare," *Injury*, vol. 54, no. 3, hal. S69–S73, 2023, doi: 10.1016/J.INJURY.2022.01.046.
- [20] R. Chen, B. O. Petrazzini, W. A. Malick, R. S. Rosenson, dan R. Do, "Prediction of Venous Thromboembolism in Diverse Populations Using Machine Learning and Structured Electronic Health Records," *Arteriosclerosis, Thrombosis, and Vascular Biology*, vol. 44, no. 2, hal. 491–504, 2024, doi: 10.1161/ATVBAHA.123.320331.
- [21] M. Hobensack, J. Song, D. Scharp, K. H. Bowles, dan M. Topaz, "Machine learning applied to electronic health record data in home healthcare: A scoping review," *International Journal of Medical Informatics*, vol. 170, no. February, hal. 104978, 2023, doi: 10.1016/j.ijmedinf.2022.104978.
- [22] K. Arumugam, M. Naved, P. P. Shinde, O. Leiva-Chauca, A. Huaman-Osorio, dan T. Gonzales-Yanac, "Multiple disease prediction using Machine learning algorithms," *Materials Today: Proceedings*, vol. 80, no. 3, hal. 3682–3685, Jan 2023, doi: 10.1016/j.matpr.2021.07.361.
- [23] A. Hennebelle, H. Materwala, dan L. Ismail, "HealthEdge: A Machine Learning-Based Smart Healthcare Framework for Prediction of Type 2 Diabetes in an Integrated IoT, Edge, and Cloud Computing System," *Procedia Computer Science*, vol. 220, hal. 331–338, 2023, doi: 10.1016/j.procs.2023.03.043.
- [24] I. S. Purba dkk., "Accuracy Level of Backpropagation Algorithm to Predict Livestock Population of Simalungun Regency in Indonesia," in *Journal of Physics: Conference Series*, 2019, hal. 012014. doi: 10.1088/1742-6596/1255/1/012014.
- [25] A. Wanto dan J. T. Hardinata, "Estimations of Indonesian poor people as poverty reduction efforts facing industrial revolution 4.0," *IOP Conference Series: Materials Science and Engineering*, vol. 725, no. 1, hal. 012114, 2020, doi: 10.1088/1757-899X/725/1/012114.
- [26] A. Wanto, S. Defit, dan A. P. Windarto, "Algoritma Fungsi Pelatihan pada Machine Learning berbasis ANN untuk Peramalan Fenomena Bencana," *RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, hal. 254–264, 2021, doi: 10.29207/resti.v5i2.3031.
- [27] I. Zuhrufillah, F. Anggraini, dan R. Dewantara, "Peramalan Jumlah Kasus Baru HIV Menurut Provinsi Menggunakan Machine Learning dengan Teknik Levenberg-Marquardt," *Journal of Computer System and Informatics (JoSYC)*, vol. 3, no. 4, hal. 212–221, 2022, doi: 10.47065/josyc.v3i4.2172.
- [28] A. Anas Manurung, I. Satria, dan A. Wanto, "Prediksi Perkembangan Produksi Tanaman Sayuran Dalam Upaya Pemenuhan Gizi Masyarakat dengan Algoritma Resilient," *Jurnal Riset Sistem Informasi Dan Teknik Informatika (JURASIK)*, vol. 8, no. 2, hal. 802–815, 2023, [Daring]. Tersedia pada: <https://tunasbangsa.ac.id/ejurnal/index.php/jurasik>
- [29] Safruddin, E. Efendi, R. M. Ch, dan 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, hal. 473–483, 2023, doi: 10.30865/mib.v7i1.5524.
- [30] I. Zuhrufillah, F. Anggraini, dan R. Dewantara, "Peramalan Jumlah Kasus Baru HIV Menurut Provinsi Menggunakan Machine Learning dengan Teknik Levenberg-Marquardt," *Journal of Computer System and Informatics (JoSYC)*, vol. 3, no. 4, hal. 212–221, 2022, doi: 10.47065/josyc.v3i4.2172.
- [31] A. A. Manurung, I. Satria, dan A. Wanto, "JST: Prediksi Perkembangan Produksi Tanaman Sayuran Dalam Upaya Pemenuhan Gizi Masyarakat dengan Algoritma Resilient," *Jurasik (Jurnal Riset Sistem Informasi dan Teknik Informatika)*, vol. 8, no. 2, hal. 802–815, 2023, doi: 10.30645/jurasik.v8i2.658.