

# Algoritma Bayesian Regulation untuk Prediksi Kemiskinan Sebagai Evaluasi Awal Mendukung Kebijakan Ekonomi Hijau

Fahmi Firzada\*, Surya Darma

STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Jln. Sudirman Blok A No. 1-3, 21143, Pematangsiantar, Indonesia

Email: <sup>1,\*</sup> fahmifirzada@amiktunasbangsa.ac.id, <sup>2</sup> suryadarma@amiktunasbangsa.ac.id

Email Penulis Korespondensi: fahmifirzada@amiktunasbangsa.ac.id

Submitted: 02/10/2024; Accepted: 30/11/2024; Published: 30/11/2024

**Abstrak**—Penelitian ini bertujuan untuk memanfaatkan algoritma Bayesian Regulation dalam prediksi kemiskinan di Simalungun, Pematangsiantar, Asahan, Batu Bara, dan Tebing Tinggi, sebagai langkah evaluasi awal untuk mendukung kebijakan Ekonomi Hijau. Kemiskinan masih menjadi permasalahan yang serius di daerah tersebut, khususnya di Pematangsiantar dan Simalungun, yang dihadapkan pada kesenjangan sosial dan rendahnya akses terhadap layanan dasar. Tingginya tingkat kemiskinan dan keterbatasan sumber daya yang ada menjadi tantangan besar dalam menciptakan kesejahteraan masyarakat. Penerapan kebijakan Ekonomi Hijau dapat menjadi solusi potensial untuk mengurangi dampak negatif pembangunan terhadap lingkungan dan meningkatkan kesejahteraan masyarakat. Penelitian ini menggunakan data sekunder time-series kemiskinan tahun 2012-2023 yang diperoleh dari BPS Sumatera Utara menggunakan konsep kemampuan memenuhi kebutuhan dasar. Algoritma Machine Learning yang diterapkan adalah Bayesian Regulation. Algoritma ini digunakan untuk memprediksi tingkat kemiskinan di daerah tersebut berlandaskan 5 model arsitektur (10-5-1, 10-10-1, 10-15-1, 10-20-1, dan 10-25-1). Berdasarkan analisis, model 10-25-1 terpilih sebagai model terbaik dan akan digunakan untuk melakukan prediksi kemiskinan, karena memiliki nilai MSE (kesalahan) yang kecil, dibandingkan 4 model yang lain, yakni sebesar 0,00218055780. Hasil penelitian ini diharapkan dapat memberikan pemahaman dan informasi tentang perkembangan kemiskinan di daerah tersebut, serta memberikan evaluasi awal terhadap efektivitas kebijakan Ekonomi Hijau yang telah dan akan diterapkan. Penelitian ini juga diharapkan dapat memberikan rekomendasi kebijakan yang lebih efektif dalam mengurangi kemiskinan dan mendukung keberlanjutan lingkungan, khususnya di Pematangsiantar dan Simalungun.

**Kata Kunci:** Machine Learning; Prediksi; Kemiskinan; Bayesian Regulation; Ekonomi Hijau

**Abstract**—This study aims to utilize the Bayesian Regulation algorithm to predict poverty in Simalungun, Pematangsiantar, Asahan, Batu Bara, and Tebing Tinggi, as an initial step to evaluate the Green Economy policy. Poverty remains a serious issue, particularly in Pematangsiantar and Simalungun, where social inequality and limited access to basic services are prevalent. High poverty rates and limited resources present significant challenges to improving community welfare. The Green Economy policy could be a potential solution to reduce the negative environmental impact of development and enhance community well-being. This research uses secondary time-series poverty data from 2012 to 2023, obtained from the Central Bureau of Statistics of North Sumatra, based on the basic needs approach. The applied Machine Learning algorithm is Bayesian Regulation, used to predict poverty levels in these areas based on five architectural models (10-5-1, 10-10-1, 10-15-1, 10-20-1, and 10-25-1). The 10-25-1 model was selected as the best model due to its smallest MSE (error), 0.00218055780, compared to the other four models. This study aims to provide insights into the development of poverty in these regions and offer an initial evaluation of the effectiveness of the Green Economy policy. It is also expected to propose more effective policy recommendations for reducing poverty and supporting environmental sustainability, particularly in Pematangsiantar and Simalungun.

**Keywords:** Machine Learning; Prediction; Poverty; Bayesian Regulation; Green Economy

## 1. PENDAHULUAN

Permasalahan kemiskinan di Kota Pematangsiantar dan Kabupaten Simalungun masih menjadi tantangan besar [1]–[5]. Kedua daerah ini memiliki jumlah penduduk miskin yang cukup tinggi, yang mengindikasikan adanya ketimpangan sosial dan kesenjangan ekonomi yang signifikan. Kemiskinan yang tinggi berdampak pada kualitas hidup masyarakat, seperti terbatasnya akses terhadap pendidikan, kesehatan, dan layanan dasar lainnya. Masyarakat yang hidup dalam kemiskinan sering kali terjebak dalam lingkaran kesulitan ekonomi, yang menghambat kesempatan mereka untuk berkembang dan meningkatkan kesejahteraan. Selain itu, tingginya angka kemiskinan ini juga membebani pemerintah dalam upaya pembangunan sosial dan peningkatan kualitas hidup masyarakat. Akibatnya, kesenjangan sosial semakin melebar dan dapat memperburuk stabilitas sosial di daerah tersebut. Beban ekonomi yang terus meningkat menyebabkan kesulitan bagi masyarakat untuk memenuhi kebutuhan dasar mereka, sehingga meningkatkan angka pengangguran, kriminalitas, dan ketidakstabilan sosial. Hal ini menjadi kendala besar dalam mewujudkan pembangunan yang inklusif dan berkelanjutan. Penyebab utama dari kemiskinan yang terus tinggi ini juga terkait dengan keterbatasan sumber daya yang ada dan terbatasnya akses terhadap peluang ekonomi yang setara. Karena itu, dibutuhkan solusi yang lebih inovatif untuk memprediksi dan mengatasi masalah kemiskinan. Salah satunya adalah penggunaan teknik Machine Learning, khususnya Bayesian Regulation [6]–[11], untuk memodelkan dan memprediksi pola kemiskinan. Dengan memanfaatkan data time series [12]–[14], penelitian ini dapat memberikan gambaran yang lebih jelas mengenai tren kemiskinan, serta faktor-faktor yang mempengaruhi perubahan tingkat kemiskinan di daerah tersebut. Solusi

berbasis data yang akurat dan dapat diandalkan akan memberikan landasan yang kuat bagi pengambilan keputusan kebijakan yang lebih tepat sasaran dalam mengurangi kemiskinan dan menciptakan pembangunan yang lebih merata [15]–[19].

Secara umum, pendekatan dan strategi pemecahan masalah pada penelitian ini antara lain: Pendekatan dengan memanfaatkan metode Machine Learning Bayesian Regulation untuk memodelkan hubungan antara variabel input time-series [20]–[24], dengan tingkat kemiskinan di lima daerah tersebut. Strategi nya dengan mengumpulkan data time-series tingkat kemiskinan, melakukan preprocessing data, mengimplementasikan metode Bayesian Regulation untuk membangun model prediksi, dan mengevaluasi kinerja model menggunakan metrik evaluasi yang sesuai seperti *Mean Squared Error* (MSE). Pendekatan berikutnya dengan Melakukan eksperimen untuk memilih model arsitektur machine learning yang optimal dengan variasi jumlah neuron, fungsi aktivasi, dan metode pembelajaran. Strategi nya dengan mengeksplorasi berbagai model arsitektur termasuk dengan variasi jumlah neuron dan fungsi aktivasi, melatih model menggunakan berbagai metode pembelajaran, dan mengoptimalkan parameter model seperti learning rate.

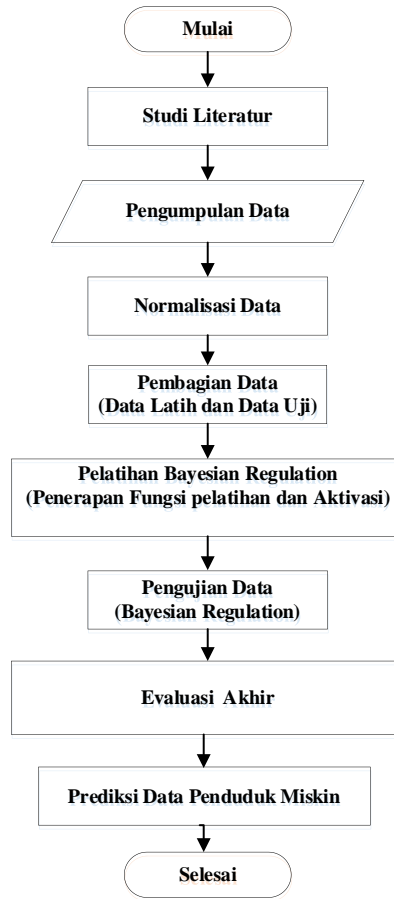
Penelitian-penelitian terdahulu terkait topik penelitian yang menjadi dasar dilakukannya penelitian ini, antara lain: Penelitian untuk mengidentifikasi prediktor kemiskinan energi di Eropa menggunakan machine learning. Penelitian ini menggunakan 2 (dua) teknik *machine learning*: pertama *gradient boosting* untuk menemukan hubungan kompleks dalam kumpulan data besar yang akan membutuhkan banyak tenaga kerja manual menggunakan uji statistik tradisional atau menjalankan dan mengevaluasi regresi standar. Kedua, dengan menerapkan metode *eXplainable Artificial Intelligence* (XAI), untuk memperoleh wawasan yang signifikan tentang hubungan rumit antara input dan output model ML, yang memfasilitasi pemahaman sistem yang cerdas [25]. Perbedaan penelitian ini dengan penelitian yang diusulkan terletak pada dataset penelitian dan algoritma yang digunakan. Penelitian berikutnya menggunakan *machine learning* untuk pengukuran dan determinan kemiskinan energi multidimensi ekstrim. Penelitian ini menggunakan *Multidimensional Energy Poverty Index* (MEPI) dan pendekatan pembelajaran mesin terawasi lanjutan, seperti Seleksi Fitur dan JST Multilayer Perceptron, untuk mengidentifikasi faktor penentu sosial ekonomi dari kemiskinan energi rumah tangga [26]. Perbedaan penelitian ini dengan penelitian yang diusulkan diantaranya dataset penelitian dan algoritma yang digunakan, tetapi masih dalam ruang lingkup yang sama, yakni *machine learning*. Penelitian menggunakan pendekatan estimasi berdasarkan pemodelan Bayesian untuk melihat kesalahan klasifikasi, bias regresi biner, dan keandalan pengukuran kemiskinan multidimensi. Artikel ini mengacu pada literatur teoretis sebelumnya untuk mengembangkan penduga kesalahan klasifikasi populasi dan bias koefisien regresi biner berbasis Bayesian [27]. Perbedaan penelitian ini dengan penelitian yang diusulkan terletak pada dataset penelitian dan algoritma yang digunakan. Penelitian untuk melakukan peramalan kemiskinan dan efisiensi energi ekonomi pada agroekosistem berbasis jagung dengan Jaringan saraf tiruan (JST) Feed-Forward Back Propagation di Meksiko. Hasilnya Feed-Forward Backpropagation membantu dalam memperkirakan variabel-variabel dengan dampak terbesar terhadap agroekosistem terkait dengan Efisiensi Ekonomi [28]. Perbedaan penelitian ini dengan penelitian yang diusulkan terletak pada dataset penelitian dan algoritma yang digunakan. Penelitian untuk melakukan prediksi kemiskinan menggunakan dataset E-commerce dan algoritma machine learning dengan pendekatan pemilihan fitur berbasis filter, yang dapat memberikan informasi lebih cepat dibandingkan survei atau sensus. Tiga algoritma *machine learning* seperti *Support Vector Regression*, *Linear Regression*, and *K-Nearest Neighbor* dibandingkan untuk memprediksi tingkat kemiskinan [29].

Berdasarkan penelitian-penelitian terdahulu yang telah dijabarkan, kebaruan yang ditawarkan dari penelitian ini antara lain: Penggunaan algoritma Bayesian Regulation dalam topik prediksi kemiskinan yang masih tergolong baru. Algoritma ini dapat memperhitungkan ketidakpastian dan variabilitas dalam prediksi, sehingga dapat memberikan hasil prediksi yang lebih akurat dan reliabel. Penelitian ini menghubungkan prediksi kemiskinan dengan konsep Green Economy, yang merupakan konsep ekonomi yang berfokus pada pengembangan berkelanjutan dan ramah lingkungan. Hal ini juga sebagai evaluasi awal untuk mengukur dampak kebijakan tersebut terhadap pengentasan kemiskinan di Indonesia. Secara garis besar hasil dari penelitian ini diharapkan akan memberikan kontribusi bagi pemerintah daerah sebagai acuan, referensi dan informasi mengenai tingkat kemiskinan di daerah tersebut pada masa yang akan datang.

## 2. METODOLOGI PENELITIAN

### 2.1 Flowchart (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-langkah nya dapat dilihat pada Gambar 1 berikut ini.



Gambar 1. Flowchart (Tahapan Penelitian)

- 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 penduduk miskin 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) [30]–[32].

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

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 *Bayesian Regulation*. 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 *Bayesian Regulation* (Penerapan Fungsi Pelatihan dan Aktivasi)  
Tahap ini merupakan proses di mana model arsitektur awal dibangun menggunakan algoritma *Bayesian Regulation*, 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 (*Bayesian Regulation*)  
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 *Bayesian Regulation*.

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 Data Penduduk Miskin

Tahap terakhir dalam penelitian ini adalah melakukan prediksi data penduduk miskin di Simalungun, Pematangsiantar, Asahan, Batu Bara, dan Tebing tinggi, menggunakan model arsitektur terbaik dari algoritma *Bayesian Regulation*.

Nilai Prediksi diperoleh dengan menggunakan algoritma terbaik dan berdasarkan model terbaik pula. Rumus perhitungannya diperoleh dengan membalikkan rumus persamaan (1) yang sudah dijelaskan sebelumnya [33]–[35].

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

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 *Bayesian Regulation*

Penelitian ini menggunakan algoritma machine learning dengan metode *Bayesian Regulation*. Teknik ini merupakan fungsi pelatihan jaringan yang memperbarui bobot dan nilai bias sesuai dengan optimasi *Levenberg-Marquardt*. Hal Ini dengan meminimalkan kombinasi kesalahan kuadrat dan bobot, dan kemudian menentukan kombinasi yang benar sehingga menghasilkan jaringan yang digeneralisasi dengan baik [36]. Teknik *Bayesian Regulation* dapat dirumuskan sebagai berikut:

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

Dimana: *net* merupakan Pembentukan Jaringan. *TR* merupakan Catatan pelatihan awal yang dibuat berdasarkan data latih di setiap epoch (iterasi). *Trainbr* merupakan Fungsi pelatihan *Bayesian Regulation*. *trainV* merupakan Data pelatihan yang dibuat berdasarkan data latih. *valV* merupakan Data validasi yang dibuat berdasarkan data latih. *testV* merupakan Data uji yang dibuat berdasarkan data latih.

3. HASIL DAN PEMBAHASAN

3.1 Data Penelitian

Data penelitian ini berupa dataset *times-series* penduduk miskin di Simalungun, Pematangsiantar, Asahan, Batu Bara, dan Tebing tinggi tahun 2012-2023. Data penelitian diperoleh dari Badan Pusat Statistik (BPS) Sumatera Utara. Informasi lengkapnya dapat dilihat pada Tabel 1 berikut ini.

Tabel 1. Data Penduduk Miskin

No	Kabupaten / Kota	Data Penduduk Miskin (Ribu Jiwa)									
		2012	2013	2014	2015	...	2020	2021	2022	2023	
A	Simalungun	83,09	87,72	86,25	92,89	...	73,64	76,99	72,47	69,21	
B	Pematangsiantar	26,01	26,61	25,43	25,83	...	21,23	22,06	20,53	18,96	
C	Asahan	72,32	80,54	76,97	85,16	...	66,32	69,29	64,49	61,69	
D	Batu Bara	43,66	46,86	44,72	50,37	...	49,78	52,59	49,39	49,18	
E	Tebing Tinggi	18,02	17,98	17,20	18,80	...	16,32	17,37	16,34	16,36	

Berdasarkan data yang disajikan pada Tabel 1, jumlah penduduk miskin di daerah tersebut cenderung fluktuatif dan naik turun. Misalnya saja penduduk miskin di Simalungun pada tahun 2020 tercatat sebanyak 73,64 ribu jiwa, dan mengalami kenaikan menjadi 76,99 ribu jiwa pada tahun 2021, sedangkan pada tahun 2022 dan tahun 2023 data penduduk miskin cenderung menurun. Begitu pula halnya di Pematangsiantar, pada tahun 2020 jumlah penduduk miskin yang terdata sebanyak 21,23 ribu jiwa dan meningkat di tahun 2021 menjadi 22,06 ribu jiwa. Sedangkan trennya di tahun 2022 dan 2023 data penduduk miskin cenderung menurun. Perkembangan data penduduk miskin di daerah lain juga hampir sama, hanya Tebing Tinggi saja di tahun 2023 penduduk miskinnya meningkat, walaupun jumlahnya tidak terlalu signifikan.

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

Pada tahapan ini, data yang telah disajikan di Tabel 1 akan dinormalisasi menggunakan persamaan (1), dan kemudian dibagi menjadi dua bagian (data latih dan data uji). Data tahun 2012 (X1) - 2021 (X10) akan digunakan sebagai input data latih, dan data tahun 2022 (Y1) digunakan sebagai target (*output*) data latih. Sedangkan Data tahun 2013 (X11) - 2022 (X20) akan digunakan sebagai input data uji, dan data tahun 2023 (Y2) digunakan sebagai target (*output*) data uji. Hasil normalisasi dan pembagian data dapat dilihat pada Tabel 2 berikut.

**Tabel 2.** Hasil Normalisasi dan Pembagian Data Latih

Data	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	Y1
A	0,797 64	0,8460 0	0,8306 4	0,9000 0	0,8926 9	0,8839 1	0,7684 9	0,7270 3	0,6989 3	0,7339 2	0,6867 1
B	0,201 42	0,2076 9	0,1953 6	0,1995 4	0,1896 2	0,1945 3	0,1596 4	0,1594 3	0,1514 9	0,1601 6	0,1441 8
C	0,685 14	0,7710 0	0,7337 1	0,8192 6	0,8108 0	0,8036 9	0,7041 5	0,6664 4	0,6224 7	0,6534 9	0,6033 6
D	0,385 78	0,4192 1	0,3968 5	0,4558 7	0,4459 5	0,4615 1	0,4706 0	0,4568 1	0,4497 1	0,4790 6	0,4456 3
E	0,117 97	0,1175 5	0,1094 0	0,1261 1	0,1231 9	0,1288 3	0,1035 5	0,1000 0	0,1002 1	0,1111 8	0,1004 2

Tabel 2 menunjukkan hasil normalisasi data dan pembagian data latih yang digunakan dalam analisis. Setiap baris pada tabel mewakili satu set data yang terdiri dari 10 variabel input (X1 hingga X10) dan satu variabel output (Y1). Nilai-nilai pada kolom X1 hingga X10 adalah hasil normalisasi dari data asli, yang dilakukan untuk memastikan bahwa semua variabel berada pada skala yang sama, memudahkan proses pelatihan model dan meningkatkan akurasi prediksi. Data latih yang terdaftar, yaitu A, B, C, D, dan E, memiliki nilai-nilai berbeda pada setiap kolom, mencerminkan variasi yang ada dalam dataset yang akan digunakan untuk melatih model. Setiap data latih ini akan digunakan untuk membangun model prediksi yang diharapkan dapat menghasilkan hasil yang lebih akurat dalam memprediksi nilai Y1 berdasarkan nilai-nilai X1 hingga X10

**Tabel 3.** Hasil Normalisasi dan Pembagian Data Uji

Data	X11	X12	X13	X14	X15	X16	X17	X18	X19	X20	Y2
A	0,846 00	0,8306 4	0,9000 0	0,8926 9	0,8839 1	0,7684 9	0,7270 3	0,6989 3	0,7339 2	0,6867 1	0,6526 6
B	0,207 69	0,1953 6	0,1995 4	0,1896 2	0,1945 3	0,1596 4	0,1594 3	0,1514 9	0,1601 6	0,1441 8	0,1277 8
C	0,771 00	0,7337 1	0,8192 6	0,8108 0	0,8036 9	0,7041 5	0,6664 4	0,6224 7	0,6534 9	0,6033 6	0,5741 1
D	0,419 21	0,3968 5	0,4558 7	0,4459 5	0,4615 1	0,4706 0	0,4568 1	0,4497 1	0,4790 6	0,4456 3	0,4434 4
E	0,117 55	0,1094 0	0,1261 1	0,1231 9	0,1288 3	0,1035 5	0,1000 0	0,1002 1	0,1111 8	0,1004 2	0,1006 3

Tabel 3 menunjukkan hasil normalisasi dan pembagian data uji yang digunakan untuk menguji model. Setiap baris mewakili satu data uji dengan 10 variabel input (X11 hingga X20) dan satu output (Y2). Nilai-nilai pada kolom X11 hingga X20 adalah hasil normalisasi data, yang bertujuan untuk menyamakan skala variabel. Data uji ini digunakan untuk menguji kemampuan model dalam memprediksi nilai Y2 berdasarkan input yang diberikan. Proses ini penting untuk mengevaluasi akurasi model pada data yang belum dilihat sebelumnya..

### 3.3 Pelatihan Bayesian Regulation (Penerapan Fungsi Pelatihan dan Aktivasi)

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

#### 3.3.1 Model Arsitektur Jaringan 10-5-1

Hasil pelatihan menggunakan model arsitektur 10-5-1 dapat dilihat pada Tabel 4. Hasil pelatihan dengan menggunakan model arsitektur ini menghasilkan Jumlah SSE sebesar 0,00000000371 dan nilai MSE sebesar 0,00000000074, dengan kata lain proses pelatihan dengan algoritma *Bayesian Regulation* sangat baik karena tingkat kesalahan nya 0.

**Tabel 4.** Hasil Pelatihan Model Arsitektur 10-5-1

Data	Target	Output	Error	SSE
A	0,68671	0,68670	0,00001	0,00000000007
B	0,14418	0,14420	-0,00002	0,00000000028
C	0,60336	0,60340	-0,00004	0,00000000198
D	0,44563	0,44560	0,00003	0,00000000106
E	0,10042	0,10040	0,00002	0,00000000032
Jumlah SSE				0,00000000371

Data	Target	Output	Error	SSE
			MSE	0,00000000074

Keterangan: Data A merupakan data Kabupaten Simalungun, data B data Kota Pematangsiantar, data C data daerah Asahan, data D daerah Batu Bara. Nilai Target diperoleh dari Target (Y1) 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 <sup>2</sup>. Jumlah SSE diperoleh dari penjumlahan SSE. Sedangkan MSE diperoleh dari Jumlah SSE / 5 (banyak nya data).

### 3.3.2 Model Arsitektur Jaringan 10-10-1, 10-15-1, 10-20-1, dan 10-25-1

Pelatihan berikutnya dilakukan menggunakan model arsitektur 10-10-1, 10-15-1, 10-20-1, dan 10-25-1. Hasil nya keempat model arsitektur tersebut memperoleh nilai yang sama dengan hasil pelatihan pada model arsitektur 10-5-1 yang terdapat pada Tabel 4, dengan Jumlah SSE sebesar 0,00000000371 dan nilai MSE sebesar 0,00000000074. Sehingga cukup kami tampilkan satu saja, karena memiliki hasil yang sama..

**Tabel 5.** Hasil Pelatihan Model Arsitektur 10-10-1, 10-15-1, 10-20-1, dan 10-25-1

Data	Target	Output	Error	SSE
A	0,68671	0,68670	0,00001	0,00000000007
B	0,14418	0,14420	-0,00002	0,00000000028
C	0,60336	0,60340	-0,00004	0,00000000198
D	0,44563	0,44560	0,00003	0,00000000106
E	0,10042	0,10040	0,00002	0,00000000032
Jumlah SSE				0,00000000371
MSE				0,00000000074

### 3.4 Pengujian Data

Setelah seluruh model arsitektur selesai dilatih, maka langkah selanjutnya adalah melakukan pengujian data terhadap masing-masing model arsitektur yang digunakan (10-10-1, 10-15-1, 10-20-1, dan 10-25-1), analisis ini dilakukan untuk melihat dan mencari model arsitektur yang terbaik yang akan digunakan untuk melakukan prediksi data.

#### 3.4.1 Model Arsitektur Jaringan 10-5-1

Hasil pengujian algoritma *Bayesian Regulation* dengan model arsitektur 10-5-1 dapat dilihat pada Tabel 6. Berdasarkan hasil pengujian, diperoleh Jumlah SSE sebesar 0,01172236053 dan nilai MSE sebesar 0,00234447211.

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

Data	Target	Output	Error	SSE
A	0,65266	0,71960	-0,06694	0,00448136460
B	0,12778	0,14490	-0,01712	0,00029294698
C	0,57411	0,65440	-0,08029	0,00644666210
D	0,44344	0,46580	-0,02236	0,00050001024
E	0,10063	0,10180	-0,00117	0,00000137660
Jumlah SSE				0,01172236053
MSE				0,00234447211

Berdasarkan perbandingan antara hasil pelatihan dan hasil pengujian, terdapat perbedaan yang cukup jauh antara nilai SSE, Jumlah SSE, dan nilai MSE. Tetapi hal ini tidak terlalu menjadi masalah, dengan syarat nilai SSE, Jumlah SSE, dan nilai MSE masih dalam skala 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 uji.

#### 3.4.2 Model Arsitektur Jaringan 10-10-1

Hasil pengujian algoritma *Bayesian Regulation* dengan model arsitektur 10-10-1 dapat dilihat pada Tabel 7. Berdasarkan hasil pengujian, diperoleh Jumlah SSE sebesar 0,01120470743 dan nilai MSE sebesar 0,00224094149.

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

Data	Target	Output	Error	SSE
A	0,65266	0,71860	-0,06594	0,00434847861
B	0,12778	0,14510	-0,01732	0,00029983326
C	0,57411	0,65220	-0,07809	0,00609822123

Data	Target	Output	Error	SSE
D	0,44344	0,46480	-0,02136	0,00045628842
E	0,10063	0,10200	-0,00137	0,00000188592
Jumlah SSE				0,01120470743
MSE				0,00224094149

### 3.4.3 Model Arsitektur Jaringan 10-15-1

Hasil pengujian algoritma *Bayesian Regulation* dengan model arsitektur 10-15-1 dapat dilihat pada Tabel 8. Berdasarkan hasil pengujian, diperoleh Jumlah SSE sebesar 0,01102981990 dan nilai MSE sebesar 0,00220596398.

**Tabel 8.** Hasil Pengujian Model Arsitektur 10-15-1

Data	Target	Output	Error	SSE
A	0,65266	0,71820	-0,06554	0,00429588422
B	0,12778	0,14520	-0,01742	0,00030330640
C	0,57411	0,65150	-0,07739	0,00598938367
D	0,44344	0,46440	-0,02096	0,00043935969
E	0,10063	0,10200	-0,00137	0,00000188592
Jumlah SSE				0,01102981990
MSE				0,00220596398

### 3.4.4 Model Arsitektur Jaringan 10-20-1

Hasil pengujian algoritma *Bayesian Regulation* dengan model arsitektur 10-20-1 dapat dilihat pada Tabel 9. Berdasarkan hasil pengujian, diperoleh Jumlah SSE sebesar 0,01095078623 dan nilai MSE sebesar 0,00219015725.

**Tabel 9.** Hasil Pengujian Model Arsitektur 10-20-1

Data	Target	Output	Error	SSE
A	0,65266	0,71810	-0,06544	0,00428278562
B	0,12778	0,14520	-0,01742	0,00030330640
C	0,57411	0,65110	-0,07699	0,00592763079
D	0,44344	0,46430	-0,02086	0,00043517751
E	0,10063	0,10200	-0,00137	0,00000188592
Jumlah SSE				0,01095078623
MSE				0,00219015725

### 3.4.5 Model Arsitektur Jaringan 10-25-1

Hasil pengujian algoritma *Bayesian Regulation* dengan model arsitektur 10-25-1 dapat dilihat pada Tabel 10. Berdasarkan hasil pengujian, diperoleh Jumlah SSE sebesar 0,01090278901 dan nilai MSE sebesar 0,00218055780.

**Tabel 10.** Hasil Pengujian Model Arsitektur 10-25-1

Data	Target	Output	Error	SSE
A	0,65266	0,71800	-0,06534	0,00426970702
B	0,12778	0,14520	-0,01742	0,00030330640
C	0,57411	0,65090	-0,07679	0,00589687434
D	0,44344	0,46420	-0,02076	0,00043101533
E	0,10063	0,10200	-0,00137	0,00000188592
Jumlah SSE				0,01090278901
MSE				0,00218055780

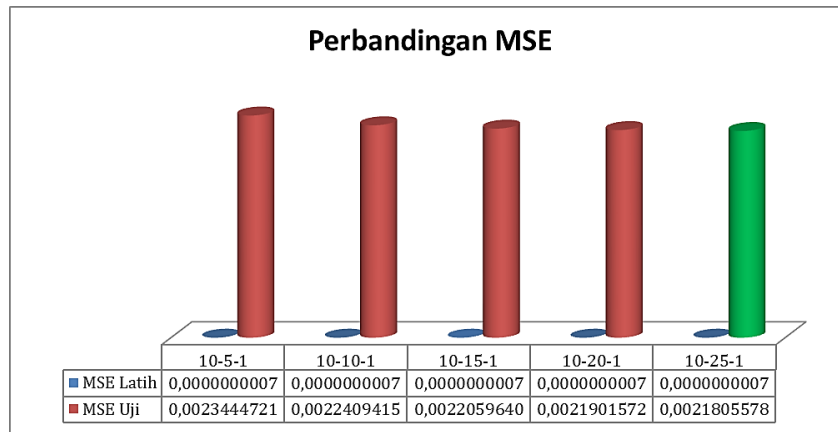
## 3.5 Evaluasi Akhir

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 *Bayesian Regulation* dengan masing-masing model arsitektur yang memiliki tingkat kesalahan terendah (terkecil), akan dipilih sebagai model arsitektur terbaik yang selanjutnya akan digunakan untuk memprediksi jumlah penduduk miskin di 5 daerah (Simalungun, Pematangsiantar, Asahan, Batu Bara, dan tebing Tinggi).

**Tabel 11.** Perbandingan Model Arsitektur dengan Algoritma *Bayesian Regulation*

Model Arsitektur	Iterasi	Fungsi Aktivasi	MSE Pelatihan	MSE Pengujian
10-5-1	354	tansig, logsig	0,0000000007	0,0023444721
10-10-1	124		0,0000000007	0,0022409415
10-15-1	229		0,0000000007	0,0022059640
10-20-1	139		0,0000000007	0,0021901572
10-25-1	120		0,0000000007	0,0021805578

Tabel 11 merupakan Perbandingan hasil data pelatihan dari masing-masing model arsitektur yang digunakan. Berdasarkan analisis dari masing-masing model arsitektur yang telah dilatih dan diuji menggunakan algoritma *Bayesian Regulation*, memperoleh hasil terbaik pada model 10-25-1, dengan nilai MSE (kesalahan) sebesar 0,00218055780.



**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 *Bayesian Regulation* dengan model arsitektur 10-25-1 terpilih sebagai model terbaik, yang nanti nya akan digunakan sebagai pedoman untuk melakukan prediksi. Landasan evaluasi adalah nilai MSE uji yang paling terendah (kecil), karena *Mean Squared Error* (MSE) merupakan suatu ukuran statistik yang digunakan untuk menilai seberapa dekat nilai yang diprediksi oleh model dengan nilai sebenarnya dalam sebuah dataset. 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.

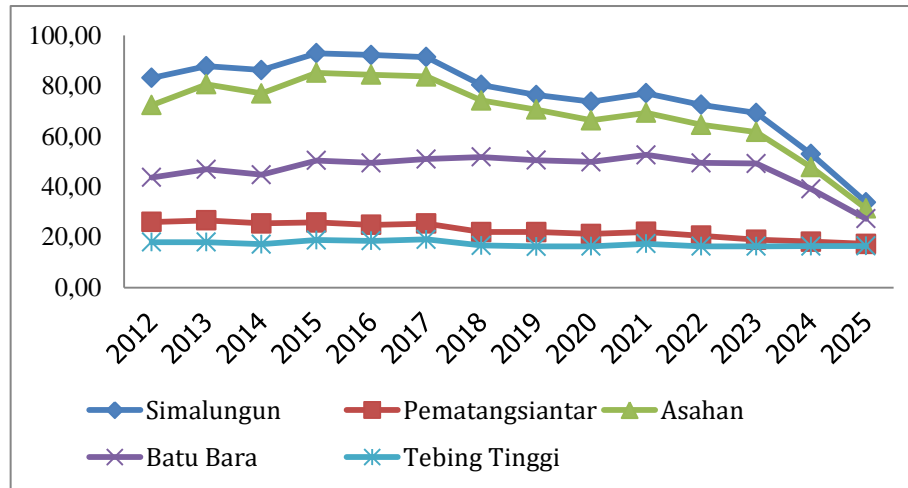
### 3.6 Prediksi Persentase Penduduk yang Mengobati Sendiri

Nilai Prediksi diperoleh dengan menggunakan algoritma Bayesian Regulation berdasarkan model terbaik 10-25-1. Rumus perhitungannya diperoleh dengan menggunakan rumus persamaan (2) yang sudah dijelaskan sebelumnya

**Tabel 12.** Prediksi Data Penduduk Miskin (Ribu Jiwa)

No	Kabupaten / Kota	Data Penduduk Miskin					Prediksi		
		2018	2019	2020	2021	2022	2023	2024	2025
A	Simalungun	80,30	76,33	73,64	76,99	72,47	69,21	52,87	33,82
B	Pematangsiantar	22,01	21,99	21,23	22,06	20,53	18,96	18,20	17,30
C	Asahan	74,14	70,53	66,32	69,29	64,49	61,69	47,68	31,34
D	Batu Bara	51,78	50,46	49,78	52,59	49,39	49,18	39,05	27,23
E	Tebing Tinggi	16,64	16,30	16,32	17,37	16,34	16,36	16,40	16,45

Tabel 12 menunjukkan prediksi jumlah penduduk miskin (dalam ribu jiwa) untuk lima kabupaten/kota di Sumatera Utara, mulai dari tahun 2018 hingga 2025. Kolom pertama menyebutkan nama kabupaten/kota, yaitu Simalungun (A), Pematangsiantar (B), Asahan (C), Batu Bara (D), dan Tebing Tinggi (E). Kolom-kolom berikutnya menunjukkan data jumlah penduduk miskin pada tahun 2018 hingga 2023, diikuti dengan prediksi jumlah penduduk miskin untuk tahun 2024 dan 2025. Berdasarkan data ini, dapat dilihat bahwa sebagian besar daerah menunjukkan tren penurunan jumlah penduduk miskin, seperti Simalungun, Asahan, dan Batu Bara, dengan prediksi yang signifikan lebih rendah pada tahun 2025 dibandingkan tahun 2018. Namun, untuk Tebing Tinggi, jumlah penduduk miskin relatif stabil sepanjang periode yang diprediksi. Tabel ini memberikan gambaran tentang perkembangan kemiskinan di setiap daerah dan dapat digunakan untuk evaluasi kebijakan serta perencanaan program pengurangan kemiskinan di masa depan.



**Gambar 3.** Grafik Penduduk Miskin

Gambar 3 tersebut merupakan grafik yang menunjukkan data jumlah penduduk miskin (dalam ribu jiwa) di lima kabupaten/kota di Sumatera Utara (Simalungun, Pematangsiantar, Asahan, Batu Bara, dan Tebing Tinggi) dari tahun 2012 hingga 2023, beserta prediksi untuk tahun 2024 dan 2025. Secara umum, terjadi tren penurunan jumlah penduduk miskin di semua wilayah selama periode tersebut. Kabupaten Simalungun memiliki jumlah penduduk miskin tertinggi setiap tahun, tetapi mengalami penurunan signifikan pada tahun 2024 dan 2025. Pematangsiantar dan Tebing Tinggi memiliki jumlah penduduk miskin terendah dan menunjukkan penurunan yang lebih stabil. Grafik juga memperlihatkan pola serupa, dengan semua wilayah mengalami penurunan tajam dalam prediksi tahun 2024 dan 2025. Penurunan ini mencerminkan potensi keberhasilan program pengentasan kemiskinan.

#### 4. KESIMPULAN

Penelitian ini memanfaatkan algoritma machine learning Bayesian Regulation untuk memprediksi tingkat kemiskinan sebagai bagian dari evaluasi awal dalam mendukung kebijakan ekonomi hijau. Beberapa model arsitektur jaringan syaraf tiruan (JST) yang diuji dalam penelitian ini meliputi 10-5-1, 10-10-1, 10-15-1, 10-20-1, dan 10-25-1. Berdasarkan hasil analisis kinerja model, arsitektur 10-25-1 terpilih sebagai model terbaik dengan nilai Mean Squared Error (MSE) terkecil, yaitu 0,0021805578. Hal ini menunjukkan bahwa model tersebut memberikan prediksi yang paling akurat dibandingkan dengan model lain yang diuji dalam penelitian ini. Hasil prediksi menunjukkan bahwa pada tahun 2024 dan 2025, diperkirakan jumlah penduduk miskin di daerah Simalungun, Pematangsiantar, Asahan, dan Batu Bara akan mengalami penurunan. Di sisi lain, di daerah Tebing Tinggi, tren kemiskinan justru diprediksi meningkat, meskipun kenaikannya tidak signifikan jika dibandingkan dengan data pada tahun 2023. Hasil ini memberikan informasi awal yang berharga bagi pemerintah dan pemangku kebijakan untuk merancang kebijakan ekonomi hijau yang lebih tepat sasaran berdasarkan distribusi kemiskinan di wilayah tersebut. Kendati demikian, penelitian ini memiliki keterbatasan, terutama dalam hal cakupan data yang digunakan. Data yang terbatas pada periode tertentu serta faktor lain yang mempengaruhi kemiskinan, seperti kebijakan sosial, kondisi lingkungan, dan akses ekonomi, belum sepenuhnya dipertimbangkan. Penelitian di masa mendatang disarankan untuk memperluas cakupan data dan mempertimbangkan variabel lain yang relevan guna meningkatkan akurasi prediksi dan mendukung kebijakan yang lebih komprehensif serta berkelanjutan.

#### REFERENCES

- [1] F. Fharuddin dan D. Endrawati, "Determinants of working poverty in Indonesia," *Journal of Economics and Development*, vol. 24, no. 3, hal. 230–246, 2022, doi: 10.1108/jed-09-2021-0151.
- [2] M. E. Siburian, "The link between fiscal decentralization and poverty – Evidence from Indonesia," *Journal of Asian Economics*, vol. 81, no. May 2021, hal. 101493, 2022, doi: 10.1016/j.asieco.2022.101493.
- [3] R. Purwono, W. W. Wardana, T. Haryanto, dan M. Khoerul Mubin, "Poverty dynamics in Indonesia: empirical evidence from three main approaches," *World Development Perspectives*, vol. 23, hal. 100346, 2021, doi: 10.1016/j.wdp.2021.100346.
- [4] A. C. Putria, T. S. Prakoso, dan M. Ohlyver, "Modeling the effect of poverty rate, GDRP, and minimum wage, on mean years of schooling in Gorontalo province with panel data regression," *Procedia Computer Science*, vol. 216, no. 1, hal. 510–516, 2023, doi: 10.1016/j.procs.2022.12.163.
- [5] S. Luckyardi, R. Hurriyati, D. Disman, dan P. D. Dirgantari, "Significances of Marketing Education in Reducing Poverty in Indonesia: Special Review on Quality of Life," *Journal of Eastern European and*

- Central Asian Research*, vol. 9, no. 1, hal. 101–111, 2022, doi: 10.15549/jeecar.v9i1.867.
- [6] T. K. Siu, “Bayesian nonlinear expectation for time series modelling and its application to Bitcoin,” *Empirical Economics*, vol. 64, no. 1, hal. 505–537, 2023, doi: 10.1007/s00181-022-02255-z.
- [7] M. Kiani Shahvandi dan B. Soja, “Inclusion of data uncertainty in machine learning and its application in geodetic data science, with case studies for the prediction of Earth orientation parameters and GNSS station coordinate time series,” *Advances in Space Research*, vol. 70, no. 3, hal. 563–575, 2022, doi: 10.1016/j.asr.2022.05.042.
- [8] R. Sujatha, J. M. Chatterjee, I. Priyadarshini, A. E. Hassanien, A. A. A. Mousa, dan S. M. Alghamdi, “Self-organizing Maps and Bayesian Regularized Neural Network for Analyzing Gasoline and Diesel Price Drifts,” *International Journal of Computational Intelligence Systems*, vol. 15, no. 1, hal. 1–16, 2022, doi: 10.1007/s44196-021-00060-7.
- [9] J. Cerri, L. Carnevali, A. Monaco, P. Genovesi, dan S. Bertolino, “Blacklists do not necessarily make people curious about invasive alien species. A case study with Bayesian structural time series and Wikipedia searches about invasive mammals in Italy,” *NeoBiota*, vol. 71, hal. 113–128, 2022, doi: 10.3897/NEOBIOTA.71.69422.
- [10] J. Han dan J. N. Ng’ombe, “The relation between wheat, soybean, and hemp acreage: a Bayesian time series analysis,” *Agricultural and Food Economics*, vol. 11, no. 1, hal. 1–12, 2023, doi: 10.1186/s40100-023-00242-1.
- [11] X. Hao, Z. Zhang, Q. Xu, G. Huang, dan K. Wang, “Prediction of f-CaO content in cement clinker: A novel prediction method based on LightGBM and Bayesian optimization,” *Chemometrics and Intelligent Laboratory Systems*, vol. 220, no. 1, hal. 104461, 2022, doi: 10.1016/j.chemolab.2021.104461.
- [12] Y. Wang, M. Perry, D. Whitlock, dan J. W. Sutherland, “Detecting anomalies in time series data from a manufacturing system using recurrent neural networks,” *Journal of Manufacturing Systems*, vol. 62, no. 1, hal. 823–834, 2022, doi: 10.1016/j.jmsy.2020.12.007.
- [13] H. Abbasimehr, R. Paki, dan A. Bahrini, “A novel approach based on combining deep learning models with statistical methods for COVID-19 time series forecasting,” *Neural Computing and Applications*, vol. 34, no. 4, hal. 3135–3149, 2022, doi: 10.1007/s00521-021-06548-9.
- [14] D. M. Ahmed, M. M. Hassan, dan R. J. Mstafa, “A Review on Deep Sequential Models for Forecasting Time Series Data,” *Applied Computational Intelligence and Soft Computing*, vol. 2022, no. Article ID 6596397, hal. 1–19, 2022, doi: 10.1155/2022/6596397.
- [15] 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.
- [16] S. Nandy, E. Fortunato, dan R. Martins, “Green economy and waste management: An inevitable plan for materials science,” *Progress in Natural Science: Materials International*, vol. 32, no. 1, hal. 1–9, 2022, doi: 10.1016/j.pnsc.2022.01.001.
- [17] X. Hao, Y. Li, S. Ren, H. Wu, dan Y. Hao, “The role of digitalization on green economic growth: Does industrial structure optimization and green innovation matter?,” *Journal of Environmental Management*, vol. 325, no. 1, hal. 116504, 2023, doi: 10.1016/j.jenvman.2022.116504.
- [18] J. Xu, S. She, P. Gao, dan Y. Sun, “Role of green finance in resource efficiency and green economic growth,” *Resources Policy*, vol. 81, no. 1, hal. 103349, 2023, doi: 10.1016/j.resourpol.2023.103349.
- [19] Z. Li, Y. Wu, E. Rasoulinezhad, Y. Sheng, dan C. Bi, “Green economic recovery in central Asia by utilizing natural resources,” *Resources Policy*, vol. 83, no. April, hal. 103621, 2023, doi: 10.1016/j.resourpol.2023.103621.
- [20] X. Ma, M. Xie, dan J. A. K. Suykens, “A novel neural grey system model with Bayesian regularization and its applications,” *Neurocomputing*, vol. 456, no. 1, hal. 61–75, 2021, doi: 10.1016/j.neucom.2021.05.048.
- [21] A. Fathabadi, S. M. Seyedian, dan A. Malekian, “Comparison of Bayesian, k-Nearest Neighbor and Gaussian process regression methods for quantifying uncertainty of suspended sediment concentration prediction,” *Science of the Total Environment*, vol. 818, no. 1, hal. 151760, 2022, doi: 10.1016/j.scitotenv.2021.151760.
- [22] N. Fiorentini, D. Pellegrini, dan M. Losa, “Overfitting Prevention in Accident Prediction Models: Bayesian Regularization of Artificial Neural Networks,” *Transportation Research Record*, vol. 2677, no. 2, hal. 1455–1470, 2023, doi: 10.1177/03611981221111367.
- [23] D. Kaplan, “On the Quantification of Model Uncertainty: A Bayesian Perspective,” *Psychometrika*, vol. 86, no. 1, hal. 215–238, 2021, doi: 10.1007/s11336-021-09754-5.
- [24] M. Breuer dan H. H. Schütt, “Accounting for uncertainty: an application of Bayesian methods to accruals models,” *Review of Accounting Studies*, vol. 28, no. 2, hal. 726–768, 2023, doi: 10.1007/s11142-021-09654-0.
- [25] W. Van Hove, F. Dalla Longa, dan B. Van der Zwaan, “Identifying predictors for energy poverty in Europe using machine learning,” *Energy and Buildings*, vol. 264, hal. 112064, 2022, doi: 10.1016/j.enbuild.2022.112064.
- [26] K. Abbas *dkk.*, “Measurements and determinants of extreme multidimensional energy poverty using

- machine learning,” *Energy*, vol. 251, no. tt1, hal. 123977, 2022, doi: 10.1016/j.energy.2022.123977.
- [27] H. Najera, “Misclassification Error, Binary Regression Bias, and Reliability in Multidimensional Poverty Measurement: An Estimation Approach Based on Bayesian Modelling,” *Measurement: Interdisciplinary Research and Perspectives*, vol. 21, no. 2, hal. 63–81, 2023, doi: 10.1080/15366367.2022.2026104.
- [28] R. Purroy Vasquez, A. A. Aguilar Lasserre, R. Meza Palacios, dan G. Fernández Lambert, “Artificial neural network (ANN) in forecasting of poverty line and economic-energetic efficiencies into the maize-based agroecosystems,” *Archives of Agronomy and Soil Science*, vol. 70, no. 1, hal. 1–17, 2024, doi: 10.1080/03650340.2023.2287751.
- [29] D. R. Wijaya, R. I. F. Ibadurrohman, E. Hernawati, dan W. Wikusna, “Poverty prediction using E-commerce dataset and filter-based feature selection approach,” *Scientific Reports*, vol. 14, no. 1, hal. 1–13, 2024, doi: 10.1038/s41598-024-52752-7.
- [30] 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.
- [31] 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.
- [32] 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.
- [33] 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.
- [34] 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>
- [35] 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.
- [36] S. Aisyah, Z. Zulkifli, dan P. A. Cakranegara, “Penerapan Algoritma Bayesian Regulation untuk Estimasi Posisi Cadangan Devisa Indonesia,” *Journal of Computer System and Informatics (JoSYC)*, vol. 3, no. 4, hal. 205 – 21 1, 2022, doi: 10.47065/josyc.v3i4.2170.