

Peramalan Data Cuaca Ekstrim Indonesia Menggunakan Model ARIMA dan *Recurrent Neural Network*

Hikmah¹, Asrirawan^{1*}, Apriyanto², Nilawati¹

¹Program Studi Statistika, Fakultas MIPA, Universitas Sulawesi Barat, Majene 91414, Indonesia

²Program Studi Matematika, Fakultas MIPA, Universitas Sulawesi Barat, Majene 91414, Indonesia

*Corresponding author. Email: asrirawan@unsulbar.ac.id

ABSTRAK

Pemodelan cuaca ekstrim merupakan tantangan bagi ahli pemodelan di Indonesia bahkan dunia. Cuaca ekstrim merupakan permasalahan yang kompleks karena peluang terjadinya sangat kecil sehingga seringkali model yang dikembangkan memiliki tingkat akurasi yang rendah. Tujuan penelitian ini adalah untuk memprediksi cuaca ekstrim menggunakan model klasik, *Autoregressive Integrated Moving Average* (ARIMA), dan model *recurrent neural network* (RNN) menggunakan estimasi Adam dan SGD (RNN-Adam dan RNN-SGD) dengan fungsi aktivasi *reLU*, *tanh*, *sigmoid* dan *gaussian*. Selain itu, model bauran ARIMA-RNN juga ditunjukkan pada penelitian ini. Model-model tersebut diterapkan pada data cuaca ekstrim periode bulanan yang diperoleh pada Badan Meteorologi Klimatologi dan Geofisika (BMKG) Provinsi Sulawesi Barat. Data tersebut diubah kedalam data latih dan data uji. Nilai RMSE digunakan untuk melihat tingkat akurasi prediksi baik pada data latih maupun data uji. Berdasarkan hasil penelitian, model terbaik yang diperoleh untuk memodelkan cuaca ekstrim Indonesia yakni model bauran ARIMA-RNN-Adam dengan fungsi aktivasi *reLU* berdasarkan nilai RMSE pada data latih dan uji. Pada saat $n = 50$, nilai RMSE dan MSE terkecil dari ketiga model adalah model bauran ARIMA-RNN-Adam yakni sebesar 0,23212 dengan menggunakan fungsi aktivasi *reLU*, kemudian model ARIMA-RNN-SGD yakni sebesar 0,25432 dengan fungsi aktivasi yang sama, sedangkan nilai ARIMA sebesar 0,3270. Pada saat $n = 100$ terlihat bahwa nilai RMSE dan MSE terkecil dari ketiga model adalah model ARIMA-RNN-Adam yakni sebesar 0,25149 dengan menggunakan fungsi aktivasi *reLU*, kemudian model ARIMA-RNN-SGD yakni sebesar 0,25256 dengan fungsi aktivasi yang sama, sedangkan nilai ARIMA sebesar 0,2644.

Kata Kunci:

Cuaca Ekstrim; Fungsi Aktivasi; ARIMA; RNN-Adam; RNN-SGD

ABSTRACT

Extreme weather modeling is a challenge for modeling experts in Indonesia and the world. Extreme weather prediction is a complex problem because the chances of it happening are very small, so the developed models often have a low level of accuracy. The purpose of this research is to combine the classic model, Autoregressive Integrated Moving Average (ARIMA), recurrent neural network (RNN) model using Adam and SGD estimation (RNN-Adam and RNN-SGD) with the reLU, tanh, sigmoid and gaussian activation functions. In addition, the ARIMA-RNN mix model was also demonstrated in this study. These models are applied to monthly period extreme weather data obtained from the Meteorology, Climatology and Geophysics Agency (BMKG) of West Sulawesi Province which are

converted into training data and test data. The RMSE value is used to see the level of prediction accuracy in both training data and test data. Based on the research results, the best model obtained for modeling Indonesia's extreme weather is the ARIMA-RNN-Adam mix model with the reLU activation function based on the RMSE value on the training and test data. At $n = 50$, the smallest RMSE and MSE values of the third model are the ARIMA-RNN-Adam model which is 0.23212 using the reLU activation function, then the ARIMA-RNN-SGD model which is 0.25432 with the same activation function, while the ARIMA value is 0.3270. At $n=100$ it can be seen that the smallest RMSE and MSE values of the three models are the ARIMA-RNN-Adam model which is equal to 0.25149 using the reLU activation function, then the ARIMA-RNN-SGD model which is equal to 0.25256 with the same activation function, while the ARIMA value is 0.2644.

Keywords:

Extreme Weather; Activation Function; ARIMA; RNN-Adam; RNN-SGD

Format Sitasi:

H. Hikmah, A. Asrirawan, A. Apriyanto, and N. Nilawati, "Peramalan Data Cuaca Ekstrim Indonesia Menggunakan Model ARIMA dan Recurrent Neural Network", *Jambura J. Math.*, vol. 5, No. 1, pp. 230–242, 2023, doi: <https://doi.org/10.34312/jjom.v5i1.17496>

1. Pendahuluan

Cuaca ekstrim (*extreme weather*) merupakan fenomena alam yang cukup sulit untuk diprediksi. Pemodelan cuaca ekstrim merupakan tantangan bagi ahli pemodelan di Indonesia maupun dunia. Sepanjang 2021, sebanyak 3.058 kasus bencana alam yang tercatat di Indonesia sejak 1 Januari hingga 28 Desember. Banjir merupakan bencana alam yang mendominasi hampir seluruh wilayah Indonesia yakni 42,10% atau sekitar 1.288 kejadian. Selain itu, tanah longsor dan kebakaran hutan dan lahan (karhutla) juga tercatat masing-masing 623 dan 265 kejadian atau sekitar 20,40% dan 8,70%. Hampir seluruh kejadian bencana alam disebabkan karena perubahan cuaca ekstrim. Sedangkan bencana alam seperti abrasi dan gelombang pasang, gempa bumi, kekeringan dan erupsi gunung meletus memiliki persentase kejadian yang lebih rendah yakni masing-masing 44, 31, 15 dan 1 kejadian (4,40%, 1,10%, 0,50% dan 0,03%). Dampak yang ditimbulkan bencana alam yang melanda Indonesia diantaranya berbagai macam fasilitas umum, bangunan hingga rumah rusak dan tak layak huni. Tercatat bahwa sebanyak 3.699 fasilitas publik, 141.795 rumah, 438 jembatan dan 509 kantor mengalami kerusakan yang parah [1].

Peran pemodelan cuaca ekstrim seperti prediksi atau peramalan akan kemungkinan kejadian yang sama pada beberapa periode kedepan tentu sangat penting dalam upaya meminimumkan terjadinya resiko pada kelangsungan hidup manusia dan sebagai bahan evaluasi serta kajian bagi pemerintah dalam pengambilan keputusan. Pada beberapa literatur, model deret waktu linier telah banyak digunakan untuk meramalkan cuaca ekstrim baik model *univariat* seperti yang terdapat pada [2, 3], maupun model *multivariat* seperti yang dapat dilihat pada [4]. Tidak hanya model berbasis peubah, tetapi model klasik dan model kontemporer juga telah dilakukan oleh ahli dalam bidang peramalan (*forecasting*). Beberapa penelitian terkait diantaranya Fang, *et al.* [5] menunjukkan bahwa prediksi cuaca ekstrim di China dengan pendekatan algoritma *deep learning* yakni *Recurrent Neural Network* (RNN), *Backpropagation Neural Network* (BPNN), *Convolutional Neural Network* (CNN) memberikan tingkat akurasi yang cukup tinggi dibandingkan dengan metode pemetaan. Han, *et al.* [6] memprediksi data cuaca dari stasiun *Harvard Graduate School of Design* (GSD) menggunakan algoritma RNN dengan tingkat akurasi yang cukup tinggi dibandingkan dengan model seperti BNN

dan NN. Wei [7] menggunakan beberapa model untuk memprediksi cuaca yakni *long short-term memory neural networks* (LSTM-NN), *deep neural networks* (DNN), *random forest* (RF), *support vector regressions* (SVR) dan *k-nearest neighbors* (K-NN). Andini dan Utomo [8] juga memprediksi data iklim kota Bandung Jawa Barat dengan menggunakan kombinasi RNN dan *Long Short Term Memory* (LSTM). Prediksi cuaca ekstrim dengan pendekatan klasik juga telah dilakukan oleh beberapa ahli seperti model *Autoregressive Integrated Moving Average* (ARIMA) telah dilakukan [9–11]. Beberapa hasil riset yang telah disebutkan menunjukkan bahwa model ARIMA sangat baik digunakan pada data deret waktu dengan periode pendek.

Prediksi dengan menggunakan RNN seringkali menemui kendala dalam hal optimasi dan fungsi aktivasi yang digunakan. Metode optimasi yang digunakan sangat menentukan tingkat konvergensi pemrosesan data. Beberapa optimasi yang bisa digunakan adalah AdaDelta, Nesterov, momentum, RMSProp, AdaGrad, Adam, Nadam GD algorithms dan AdaMax [12]. Metode estimasi Adam dan SGD sangat fleksibel dan memiliki tingkat konvergensi yang signifikan dan lebih cepat dibandingkan dengan metode lain, seperti yang dijelaskan Su dan Kek [13]. Pada penelitian ini, diperlihatkan tingkat akurasi Model RNN dengan menggunakan optimasi Adam dan SGD dan variasi fungsi aktivasi reLU, sigmoid, tanh dan gaussian. Model tersebut selanjutnya dibandingkan dengan model ARIMA serta bauran ARIMA-RNN.

2. Metode

Secara umum, langkah analisis yang dilakukan pada penelitian ini diuraikan berikut ini, mulai dari pengumpulan data, eksplorasi data hingga perbandingan beberapa model untuk memprediksi cuaca ekstrim.

2.1. Pengumpulan Data

Data yang digunakan merupakan data cuaca ekstrim periode bulanan yang diperoleh dari Badan Meteorologi, Klimatologi dan Geofisika mulai 01 Januari 2012 sampai dengan 31 Desember tahun 2021, melalui laman resmi di <https://dataonline.bmkg.go.id/>. Jumlah observasi data sebanyak 120 deret waktu yang dibagi menjadi data latih dan data uji dengan persentase masing-masing 80% dan 20%.


2.2. Deskripsi Data Deret Waktu Cuaca Ekstrim

Data yang diperoleh selanjutnya dieksplorasi secara deskriptif untuk melihat pola cuaca ekstrim yang terjadi di Indonesia apakah terdapat pola musiman dalam data. Bagian ini juga akan memberikan informasi kepada kita tentang periode kejadian tertinggi dan terendah cuaca ekstrim yang cukup signifikan.

2.3. Pemodelan RNN-Adam dan RNN-SGD

Model *Recurrent Neural Network* (RNN) memiliki sifat yang unik, yaitu dapat menyimpan data dalam struktur jaringan karena memiliki minimal satu *feedback loop*. Kelebihan dari model NN pada algoritma peramalan yakni kemampuan dalam memprediksi data deret waktu tidak linier [14, 15]. Untuk melakukan prediksi, RNN bergantung pada bobot dan arsitekturnya [16]. Selain itu, RNN memiliki hubungan umpan balik yang membawa informasi gangguan pada saat *input* sebelumnya yang

akan disimpan pada *input* berikutnya [9]. Arsitektur RNN ditampilkan pada Gambar 1.



Gambar 1. Arsitektur Recurrent Neural Network

Secara garis besar, langkah-langkah pemodelan RNN-Adam dan RNN-SGD adalah sebagai berikut:

1. Menentukan fungsi aktivasi untuk RNN, Fungsi aktivasi bertujuan untuk mengubah *input neuron* menjadi *output* lapisan. Fitur fungsi aktivasi pada jaringan neuron bersifat sederhana dan mudah dihitung. Ada banyak aktivasi fungsi yang digunakan untuk jaringan saraf. Namun, beberapa fungsi aktivasi representatif yang berpengaruh untuk melatih model RNN menjadi fokus pada penelitian ini diantaranya adalah fungsi aktivasi tidak linier. Berikut penjelasan fungsi aktivasi berikut sebagai berikut:

(a) *Rectified Linear Unit (reLU)*

Fungsi aktivasi *reLU* diperkenalkan oleh Nail [17]. Tidak seperti fungsi aktivasi *Sigmoid* dan *Tanh* yang mampu mengatasi *gradient vanishing* akan tetapi fungsi aktivasi *reLU* lebih efisien digunakan pada *deep learning* tanpa bergantung pada pra-pemrosesan. Persamaan fungsi aktivasi *reLU* dapat dituliskan seperti pada persamaan (1):

$$f(x) = \begin{cases} 0 & , x < 0 \\ x & , x \geq 0 \end{cases} \quad (1)$$

(b) *Tanh*

Fungsi aktivasi *Tanh* merupakan transformasi dari fungsi aktivasi *Sigmoid* dengan nilai unit interval -1 dan +1. Persamaan fungsi aktivasi *Tanh* dituliskan seperti pada persamaan (2):

$$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1. \quad (2)$$

(c) *Sigmoid*

Fungsi aktivasi *Sigmoid* memiliki range antara 0 dan 1. Fungsi ini dapat menjadi model probabilitas. Fungsi aktivasi *Sigmoid* dituliskan pada persamaan (3):

$$f(x) = \text{sigmoide}(x) = \frac{1}{1 + e^x}. \quad (3)$$

(d) *Gaussian*

Fungsi aktivasi *Gaussian* memiliki kurva berbentuk lonceng dan berguna untuk memodelkan variabel acak terdistribusi Gaussian. Fungsi Gaussian adalah kasus khusus dari keluarga fungsi aktivasi fungsi basis radial (RBF), yang fungsinya selalu memiliki kurva berbentuk lonceng. Anggota lain dari keluarga RBF termasuk *poliharmonik spline* dan fungsi benjolan. Fungsi *Gaussian* dituliskan pada persamaan (4):

$$f(x) = e^{-\frac{x^2}{2\sigma^2}}, \sigma > 0 \quad (4)$$

dimana σ merupakan nilai *spread*.

2. Melakukan optimasi model RNN dengan metode ADAM

Metode optimasi RNN-Adam telah mempertimbangkan cara efisien yang digunakan untuk meningkatkan laju pembelajaran algoritma jaringan syaraf tiruan untuk setiap parameter dalam kumpulan parameter yang digunakan [18]. Prinsipnya menganggap bahwa rata-rata gradien eksponensial (seperti momentum) dan gradien kuadratik, masing-masing disebut sebagai momen pertama dan momen kedua yang kemudian dinamakan dengan *adaptif moment* (ADAM). Penggunaan gradien kuadrat untuk memperkirakan kecepatan pembelajaran momen pertama dan kedua dari gradien yang bertujuan untuk mengubah kecepatan setiap bobot jaringan. Langkah-langkah pengoptimalan RNN menggunakan optimasi adam, dilakukan sebagai berikut:

- (a) Mendefinisikan turunan gradien
- (b) Menentukan momentum pertama
- (c) Menentukan momentum kedua
- (d) Menentukan nilai iterasi
- (e) Menentukan rumus aktivasi.

3. Melakukan optimasi model RNN dengan optimasi *Stochastic Gradient Descent* (SGD)

Dalam mengoptimalkan model *deep learning* skala besar, algoritma SGD terbukti efisien. Istilah stokastik berarti mekanisme atau metode yang berhubungan dengan kemungkinan acak. Oleh karena itu, untuk seluruh kumpulan data untuk setiap iterasi, beberapa sampel dipilih secara acak. SGD bertujuan untuk menemukan minimum global dengan mengubah struktur jaringan setelah setiap tahap pelatihan. Pendekatan ini hanya mengurangi kesalahan dengan memperkirakan gradien untuk sekumpulan yang dipilih secara acak yang bertujuan untuk menemukan gradien seluruh kumpulan data tersebut. Pada kenyataannya, pengambilan sampel acak dilakukan dengan memilih data secara acak dan bergerak bertahap melalui *batch*. SGD sering mengeksekusi perubahan varians tinggi yang memungkinkan variasi signifikan dalam fungsi tujuan. Dalam algoritme SGD, hanya satu contoh dataset yang dipilih secara acak yang digunakan untuk pembaruan. Solusi ini lebih cepat dari GD, tetapi tidak memberikan solusi dengan presisi yang sama [19, 20]. Algoritma SGD dilaksanakan mengikuti langkah-langkah sebagai berikut:

- (a) Melakukan inisialisasi θ
- (b) Menghitung nilai tingkat pembelajaran η

- (c) Mengulang langkah sebelumnya sampai konvergen.
4. Pemodelan ARIMA Model ARIMA merupakan salah satu model yang cukup banyak diterapkan pada data deret waktu. Hal ini dikarenakan model tersebut dapat mengatasi data yang tidak stasioner. Kondisi data yang memiliki rata-rata dan ragam yang berfluktuatif tidak pada rataannya dan ragamnya maka dikatakan data tersebut tidak stasioner dalam rata-rata dan ragam. Proses *differencing* dilakukan untuk data yang tidak stasioner dalam rata-rata sedangkan transformasi *Box-Cox* dilakukan untuk mengatasi data yang tidak stasioner dalam ragam. Namun perlu diperhatikan bahwa jika data tidak stasioner keduanya maka proses transformasi data perlu dilakukan pertamakali dan selanjutnya dilakukan *differencing* [21].

Diberikan N_t adalah barisan pembeda dengan rumus $N_t = Y_t - Y_{t-1}$, maka model ARMA stasioner diberikan pada (5):

$$\begin{aligned} N_t &= Y_t - Y_{t-1} \\ N_t &= \phi_1 N_{t-1} + \dots + \phi_p N_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q}. \end{aligned} \quad (5)$$

Jika nilai N_t digantikan dengan $Y_t - Y_{t-1}$ maka persamaan (5) dapat ditulis kembali pada persamaan (6):

$$\begin{aligned} Y_t &= Y_{t-1} + \phi_1 (Y_{t-1} - Y_{t-2}) + \dots + \phi_p (Y_{t-p} - Y_{t-p-1}) \\ &+ e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q}. \end{aligned} \quad (6)$$

Selanjutnya, model $ARIMA(p, d, q)$ dapat dituliskan secara matematis seperti yang dituliskan pada persamaan (7):

$$\phi_p(B) (1 - B)^d y_t = \theta_q(B) e_t, \quad (7)$$

dengan

p : orde AR, d : orde dari *differencing*, q : orde MA.

Disisi lain, pola data yang mengandung unsur musiman juga dapat dimodelkan dengan ARIMA seperti yang dituliskan pada persamaan (8):

$$\Phi_p(B) (1 - B)^D y_t = \Theta_Q(B) e_t. \quad (8)$$

Adapun kombinasi persamaan (7) dengan persamaan (8) yakni gabungan pola data musiman dan tidak musiman akan menghasilkan model multiplikatif musiman ARIMA (SARIMA) $(p, d, q)(P, D, Q)^s$ [22] yang ditampilkan pada persamaan (9):

$$\Phi_p(B) \phi_p(B^s) (1 - B)^d (1 - B)^D y_t = \Theta_Q(B^s) \theta_q(B) e_t. \quad (9)$$

Secara umum langkah pemodelan ARIMA adalah sebagai berikut:

- (a) Tahap identifikasi

Pada tahap ini dilakukan identifikasi stasioner data melalui plot dan plot ACF dan PACF. Jika data tidak stasioner dalam rata-rata dan ragam maka dilakukan teknik *differencing* dan teknik transformasi *Box-Cox*. Pada tahap ini juga dilakukan identifikasi kemungkinan orde beberapa model ARIMA

$(p, d, q)(P, D, Q)^s$.

- (b) Tahap estimasi parameter
 Pada tahap ini dilakukan estimasi parameter model yang diperoleh pada tahap 1. Jika p -value lebih kecil dari 0,05, maka parameter dianggap signifikan. Sebaliknya jika p -value lebih besar dari 0,05, maka dikatakan tidak signifikan.
- (c) Tahap uji diagnostik
 Pada tahap ini dilakukan pengujian diagnostik yakni uji kenormalan residual dan *white noise*.
- (d) Tahap peramalan
 Pada tahap ini juga dilakukan bauran ARIMA dan RNN.

2.4. Pemilihan Model Terbaik

Ukuran yang digunakan sebagai kriteria pemilihan model merujuk pada [23, 24] dimana RMSE digunakan untuk menghitung nilai galat antara nilai prediksi yang diperoleh dari hasil model dengan nilai aktual kemudian diakarkan. Rumus untuk menghitung nilai RMSE ditampilkan pada persamaan (10):


$$RMSE = \frac{\sum_{t=1}^n \sqrt{\hat{y}_t - y_t}}{n}. \tag{10}$$

3. Hasil dan Pembahasan

Bagian ini menjelaskan tentang hasil penelitian yang telah dilakukan yakni analisis secara deksriptif data cuaca ekstrim Indonesia dan analisis secara pemodelan dengan menggunakan model perbandingan antara model ARIMA, RNN menggunakan metode optimasi Adam dan SGD dan fungsi aktivasi reLu, tanh, sigmoid dan gaussian serta model bauran ARIMA-RNN, kemudian membandingkan model-model tersebut dengan kriteria nilai RMSE.

3.1. Analisis Deskripsi Cuaca Ekstrim di Indonesia

Analisis deskripsi digunakan untuk melihat pola cuaca ekstrim di Indonesia mulai tahun 2012 hingga tahun 2022 menggunakan data bulanan Januari-Desember. Plot deret waktu dan plot ACF dari data cuaca ekstrim yang terjadi di Indonesia ditunjukkan pada Gambar 2.

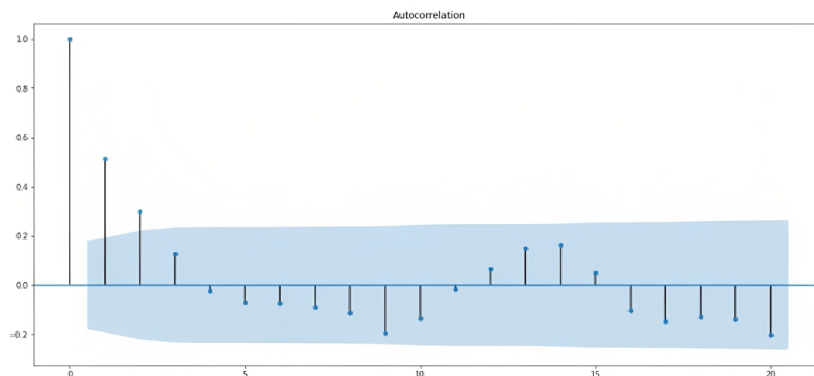


Gambar 2. Plot deret waktu data cuaca ekstrim Indonesia


Rata-rata cuaca ekstrim di Indonesia mencapai 21,98 dengan curah hujan tertinggi terjadi pada akhir tahun 2013. Selain itu, umumnya peningkatan curah hujan ekstrim terjadi di akhir-akhir tahun dan mengalami penurunan curah hujan di awal tahun. Sedangkan curah hujan terendah dalam periode 2012-2021 hampir terjadi di setiap tahun dengan sebaran datanya menuju ke nol. Hal ini disebabkan adanya variasi curah hujan yang terjadi di Indonesia. Secara spasial maupun temporal, variasi cuaca ekstrim di wilayah Indonesia sangat besar. Pola curah hujan kaitannya cuaca ekstrim di Indonesia umumnya didominasi oleh monsun yang memiliki ciri adanya perbedaan yang cukup signifikan antara musim kemarau dan hujan. Karakteristik hujan di Indonesia dikategorikan dengan di atas di bawah normal, normal dan di atas normal. Hujan normal memiliki sifat akumulasi curah hujan yang terjadi disuatu daerah prakiraan musim selama musim hujan berada pada sekitar nilai rata-rata selama 30 tahun. Karakteristik curah hujan di atas normal lebih tinggi jika dibandingkan dari batas atas nilai normalnya, sedangkan sifat hujan bawah normal memiliki sifat akumulasi curah hujan selama musim hujan lebih rendah dari batas normalnya.

3.2. Model ARIMA Musiman Cuaca Ekstrim di Indonesia

Plot data deret waktu cuaca ekstrim Indonesia seperti pada Gambar 2 menunjukkan adanya pola yang bersifat musiman hal ini juga dapat dilihat pada plot ACF dan PACF yang ditunjukkan pada Gambar 3 dan Gambar 4.



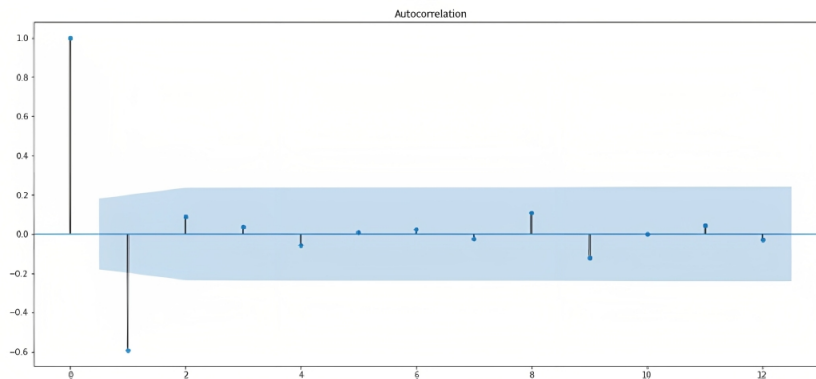
Gambar 3. Plot ACF data cuaca ekstrim Indonesia



Gambar 4. Plot PACF data cuaca ekstrim Indonesia


Pola tersebut berulang setiap tahunnya, sehingga data tersebut diidentifikasi memiliki

pola musiman 12. Selain itu, data tidak stasioner dalam rata-rata pada lag musiman dan tidak musiman berdasarkan nilai lag-lag yang turun secara lambat. Oleh karena itu, perlu dilakukan *differencing* 1 dan 12. Hasil *differencing* dari data dapat dilihat pada Gambar 5.



Gambar 5. Plot ACF data cuaca ekstrim Indonesia setelah *differencing* lag 1 dan lag 12

Setelah dilakukan *differencing* seperti yang ditunjukkan pada Gambar 5, maka diperoleh nilai Plot ACF yang menunjukkan *cut off* pada lag 1 dan 12. Selanjutnya, plot ACF dan PACF untuk data cuaca ekstrim setelah *differencing* lag 1 dan lag 12 ditampilkan pada Gambar 6.



Gambar 6. Plot ACF dan PACF data cuaca ekstrim Indonesia setelah *differencing* lag 1 dan lag 12


Plot PACF sebagaimana ditunjukkan pada Gambar 6 menunjukkan bahwa data turun secara eksponensial pada lag awal dan lag musimannya yaitu lag 12, 24, dan 36 sehingga dapat dikatakan bahwa hasil *differencing* data telah stasioner baik pada rata-rata maupun pada ragam. Oleh karena itu, model dugaannya adalah model ARIMA. Dengan demikian, model ARIMA yang cocok adalah model $(1, 1, 1)(1, 1, 1)^{12}$. Model yang telah diperoleh pada langkah sebelumnya kemudian dilakukan pendugaan parameter dengan menggunakan nilai *p-value* seperti pada Tabel 1.

Berdasarkan Tabel 1, dapat diketahui bahwa hanya ada dua parameter yang signifikan karena nilai *p-value* $< \alpha$ (0,05). Parameter yang signifikan yakni parameter pada lag 1

Tabel 1. Hasil estimasi parameter model multiplikatif musiman SARIMA $(1, 1, 1)(1, 1, 1)^{12}$

	Koef.	SE	Nilai Z	P-value	25%	75%
ϕ_1	0.5408	0.111	4.861	0.000	0.323	0.759
θ_1	-1.0000	1331.5	-0.001	0.999	-2610.6	2608.6
Φ_1	0.0112	0.010	1.102	0.270	-0.009	0.031
Θ_1	-0.8637	0.205	-4.214	0.000	-1.265	-0.462

unsur tidak musiman dan sisaan pada lag 12 pada unsur musiman. Setelah tahap estimasi parameter selanjutnya adalah melakukan pengujian residual *white noise* menggunakan *Ljung-Box* seperti yang ditampilkan pada Gambar 7.

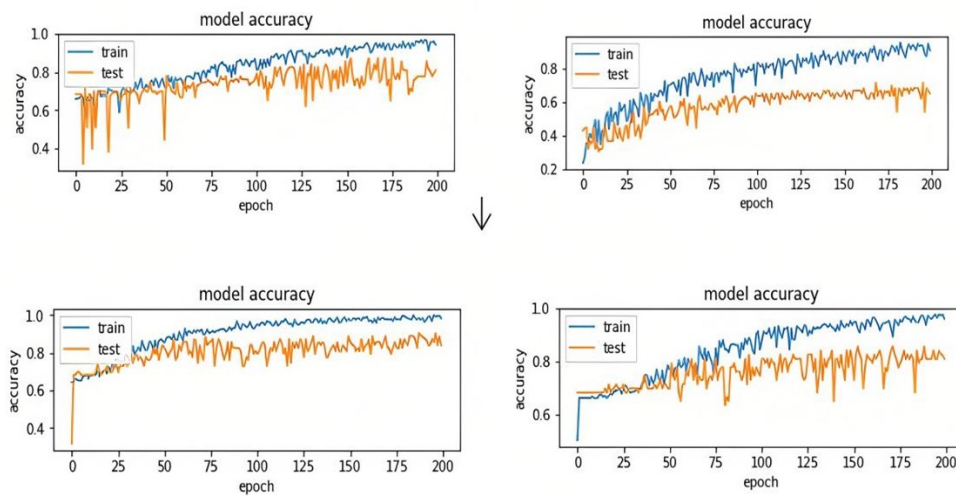


Gambar 7. Pengujian Kenormalan *Residual* dan *White Noise*

Berdasarkan Gambar 7 dan hasil analisis, dapat diketahui bahwa *residual* adalah *white noise* dan mengikuti sebaran normal. Hal ini disebabkan karena nilai *p-value* dari hasil pengujian *Ljung-Box* $> \alpha$ (0,05), sehingga bisa dilakukan ke tahap selanjutnya. Selanjutnya adalah melakukan peramalan untuk data uji untuk beberapa periode kedepan berdasarkan model terbaik musiman ARIMA $(1, 1, 1)(1, 1, 1)^{12}$.

3.3. Model ARIMA-RNN Cuaca Ekstrim di Indonesia

Untuk mendapatkan prediksi yang optimal dilakukan variasi pada waktu dataset dan durasi prediksi. Eksperimen ini juga menguji akurasi model optimisasi, model estimasi momen adaptif (Adam), dan model SGD. Akurasi dihitung dari akurasi kelas keluaran terhadap label kelas sebenarnya. Penelitian ini menggunakan dua model prediksi. Pertama, menggunakan data cuaca selama sepuluh tahun dan lima tahun. Kedua model diuji mingguan dan bulanan. Hasil akurasi model ARIMA-RNN-Adam dan ARIMA-RNN-SGD yang diteapkan pada data cuaca ekstrim 2012-2022 ditampilkan pada Gambar 8.



Gambar 8. Akurasi model ARIMA-RNN-Adam dan ARIMA-RNN-SGD pada data cuaca ekstrim 2012-2022

Pola akurasi model di yang ditunjukkan pada Gambar 8 dimaksudkan untuk mencari data yang representatif yang mewakili pola kejadian cuaca ekstrim. Data yang ditampilkan pada Gambar 8 memperlihatkan bahwa prediksi cuaca cukup memberikan akurasi yang lebih baik. Hal ini dapat dilihat dari akurasi model RNN menggunakan data *training* dan data *testing* pada Tabel 2.

Tabel 2. Akurasi Model RNN menggunakan data *training* dan *testing*

Model	Data Training (%)	Data Testing (%)
ARIMA-RNN-Adam	97,61	87,76
ARIMA-RNN-SGD	95,50	75,90

Berdasarkan Gambar 8 dan Tabel 2 terlihat model ARIMA-RNN-Adam memberikan akurasi sebesar 97,61% pada data *training*, sedangkan ARIMA-RNN-SGD juga memberikan tingkat akurasi yang cukup tinggi yakni 95,50%. Hal ini juga berlaku pada saat di ujikan pada data *testing* yang menunjukkan bahwa nilai akurasi model untuk ARIMA-RNN-Adam memberikan akurasi sebesar 87,76%, sedangkan ARIMA-RNN-SGD juga memberikan tingkat akurasi yang cukup tinggi yakni 75,90%.

3.4. Perbandingan Nilai RMSE dan MSE Model ARIMA dan RNN

Perbandingan nilai RMSE untuk ketiga model, yaitu model ARIMA-RNN-ADAM, model ARIMA-RNN-SGD, dan ARIMA disajikan pada Tabel 3.

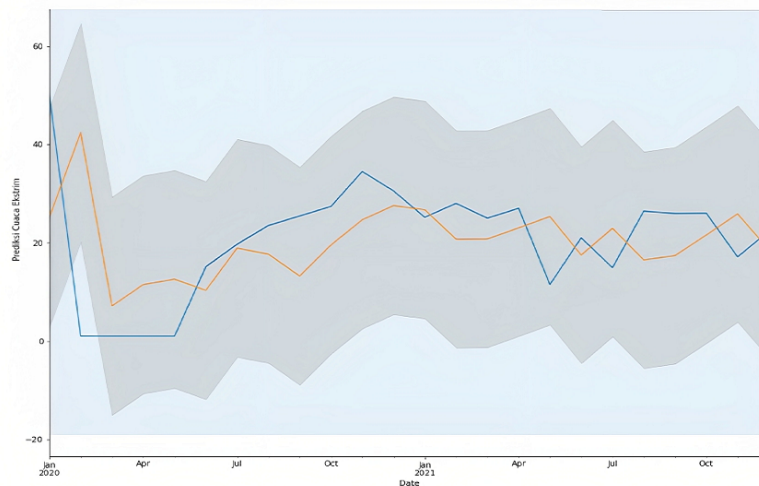
Berdasarkan Tabel 3 terlihat bahwa pada data *training* saat $n = 50$, nilai RMSE dan MSE terkecil dari ketiga model adalah model ARIMA-RNN-Adam yakni sebesar 0,23212 dengan menggunakan fungsi aktivasi reLU, kemudian model ARIMA-RNN-SGD yakni sebesar 0,25432 dengan fungsi aktivasi yang sama, sedangkan nilai ARIMA sebesar 0,3270. Pada saat $n=100$ terlihat bahwa nilai RMSE dan MSE terkecil dari ketiga model adalah model ARIMA-RNN-Adam yakni sebesar 0,25149 dengan menggunakan fungsi aktivasi reLU, kemudian model ARIMA-RNN-SGD yakni sebesar 0,25256 dengan fungsi aktivasi yang sama, sedangkan nilai ARIMA sebesar 0,2644. Adapun

Tabel 3. Perbandingan nilai RMSE ketiga model

Jumlah Neuron	Fungsi Aktivasi	Epoch	ARIMA-RNN-ADAM		ARIMA-RNN-SGD		ARIMA	
			Training	Testing	Training	Testing	Training	Testing
50	Tanh	100	0,40134	0,16108	0,42102	0,17032	0,3270	0,1069
	Sigmoid	100	0,52144	0,27190	0,58214	0,15432		
	reLU	100	0,23212	0,05388	0,25432	0,06430		
	Gaussian	100	0,31183	0,09724	0,32521	0,06250		
100	Tanh	100	0,37057	0,13732	0,43265	0,13932	0,2644	0,0691
	Sigmoid	100	0,51975	0,27015	0,52543	0,23420		
	reLU	100	0,25149	0,06325	0,25256	0,07353		
	Gaussian	100	0,30182	0,09110	0,32164	0,12314		

pada data *testing*, terlihat bahwa saat $n=50$, nilai RMSE dan MSE terkecil dari ketiga model adalah model ARIMA-RNN-Adam yakni sebesar 0,05388 dengan menggunakan fungsi akktivasi reLU, kemudian model ARIMA-RNN-SGD yakni sebesar 0,0643 dengan fungsi aktivasi yang sama, sedangkan nilai ARIMA sebesar 0,1069.

Pada saat $n = 100$ terlihat bahwa nilai RMSE dan MSE terkecil dari ketiga model adalah model ARIMA-RNN-Adam yakni sebesar 0,06325 dengan menggunakan fungsi akktivasi reLU, kemudian model ARIMA-RNN-SGD yakni sebesar 0,07353 dengan fungsi aktivasi yang sama, sedangkan nilai ARIMA sebesar 0,0691. Dari analisis di atas dapat disimpulkan bahwa model ARIMA-RNN-Adam merupakan model terbaik untuk memodelkan kasus cuaca ekstrim di Indonesia (2012-2021) secara bulanan dengan fungsi aktivasi terbaik adalah fungsi aktivasi reLU. Fungsi ini sangat baik untuk data sekuensial yang tidak linear. Gambaran perbandingan akurasi antara model ARIMA dengan model ARIMA-RNN-ADAM selanjutnya ditampilkan pada Gambar 9.



Gambar 9. Plot perbandingan akurasi peramalan model ARIMA dan ARIMA-RNN-ADAM

Berdasarkan plot data ramalan cuaca ekstrim yang ditampilkan pada Gambar 9, terlihat bahwa model ARIMA-RNN-AdDAM yang direpresentasikan dengan kurva berwarna biru lebih akurat mengikuti data aktual dibandingkan dengan model ARIMA yang direpresentasikan dengan kurva berwarna orange.

4. Kesimpulan

Model bauran ARIMA-RNN-ADAM dengan fungsi aktivasi *reLU* merupakan model terbaik untuk memprediksi cuaca ektrim Indonesia berdasarkan nilai RMSE pada data *training* dan data *testing* yang digunakan. Pada saat $n = 50$, nilai RMSE dan MSE terkecil dari ketiga model adalah model ARIMA-RNN-ADAM yakni sebesar 0,23212 dengan menggunakan fungsi aktivasi *reLU*, kemudian model ARIMA-RNN-SGD yakni sebesar 0,25432 dengan fungsi aktivasi yang sama, sedangkan nilai ARIMA sebesar 0,3270. Pada saat $n = 100$ terlihat bahwa nilai RMSE dan MSE terkecil dari ketiga model adalah model ARIMA-RNN-DAM yakni sebesar 0,25149 dengan menggunakan fungsi akktivasi *reLU*, kemudian model ARIMA-RNN-SGD yakni sebesar 0,25256 dengan fungsi aktivasi yang sama, sedangkan nilai ARIMA sebesar 0,2644.


Ucapan Terima Kasih

Ucapan terima kasih kepada Universitas Sulawesi Barat yang telah mendukung penelitian ini melalui anggaran DIPA untuk Skema Penelitian Dasar (PD) dengan nomor kontrak: 062/UN55.C/PT.01.03/2022, yang dikelola oleh Lembaga Penelitian dan Pengabdian Kepada Masyarakat dan Penjaminan Mutu (LPPM-PM) Universitas Negeri Sulawesi Barat.

Referensi

- [1] V. A. Dihni, "BNPB: Kejadian Bencana Alam Indonesia Capai 3.058 Sepanjang 2021," 2021, [Online] Available at: <https://databoks.katadata.co.id/datapublish/2021/12/29/bnpb-kejadian-bencana-alam-indonesia-capai-3058-sepanjang-2021>.
- [2] Y. W. A. Nanlohy, B. Sutijo, and S. Wulan, "Model Fungsi Transfer Multi Input Untuk Peramalan Curah Hujan di Kota Surabaya," *VARIANCE: Journal of Statistics and Its Applications*, vol. 1, no. 2, pp. 82–92, 2019.
- [3] A. M. Priyatno, A. Wiratmo, F. Syuhada, and P. Cholidhazia, "Perbandingan Imputasi dan Parameter Support Vector Regression Untuk Peramalan Cuaca," *Simetris: Jurnal Teknik Mesin, Elektro dan Ilmu Komputer*, vol. 10, no. 2, pp. 651–660, 2019, doi: <https://doi.org/10.24176/simet.v10i2.3402>.
- [4] O. Trisnawati and M. Prastuti, "Peramalan Curah Hujan di Stasiun Juanda Menggunakan Metode ARIMA Box-Jenkins dan Radial Basis Function Neural Network," *Jurnal Sains dan Seni ITS*, vol. 11, no. 1, pp. D82–D88, feb 2022, doi: [10.12962/j23373520.v11i1.63165](https://doi.org/10.12962/j23373520.v11i1.63165).
- [5] W. Fang, Q. Xue, L. Shen, and V. S. Sheng, "Survey on the Application of Deep Learning in Extreme Weather Prediction," *Atmosphere*, vol. 12, no. 6, p. 661, may 2021, doi: [10.3390/atmos12060661](https://doi.org/10.3390/atmos12060661).
- [6] J. M. Han, Y. Q. Ang, A. Malkawi, and H. W. Samuelson, "Using recurrent neural networks for localized weather prediction with combined use of public airport data and on-site measurements," *Building and Environment*, vol. 192, p. 107601, apr 2021, doi: [10.1016/j.buildenv.2021.107601](https://doi.org/10.1016/j.buildenv.2021.107601).
- [7] C. C. Wei, "Collapse Warning System Using LSTM Neural Networks For Construction Disaster Prevention In Extreme Wind Weather," *J. of Civ. Eng & Man.*, vol. 27, no. 4, pp. 230–245, apr 2021, doi: [10.3846/jcem.2021.14649](https://doi.org/10.3846/jcem.2021.14649).
- [8] N. Andini and W. H. Utomo, "Climate Prediction Using RNN LSTM to Estimate Agricultural Products Based on Koppen Classification," *JISA(Jurnal Informatika dan Sains)*, vol. 4, no. 2, pp. 96–99, dec 2021, doi: [10.31326/jisa.v4i2.911](https://doi.org/10.31326/jisa.v4i2.911).
- [9] A. G. Salman and Y. L. Prasetyo, "Implementasi Jaringan Syaraf Tiruan Recurrent Dengan Metode Pembelajaran Gradient Descent Adaptive Learning Rate Untuk Pendugaan Curah Hujan Berdasarkan Peubah Enso," *ComTech: Computer, Mathematics and Engineering Applications*, vol. 1, no. 2, pp. 418–429, dec 2010, doi: [10.21512/comtech.v1i2.2384](https://doi.org/10.21512/comtech.v1i2.2384).
- [10] A. G. Salman and B. Kanigoro, "Visibility Forecasting Using Autoregressive Integrated

- Moving Average (ARIMA) Models," *Procedia Computer Science*, vol. 179, pp. 252–259, 2021, doi: 10.1016/j.procs.2021.01.004.
- [11] W. Hariadi and S. Sulantari, "Application of ARIMA Model for Forecasting Additional Positive Cases of Covid-19 in Jember Regency," *Enthusiastic : International Journal of Applied Statistics and Data Science*, vol. 1, no. 01, pp. 20–27, apr 2021, doi: 10.20885/enthusiastic.vol1.iss1.art4.
- [12] A. Mustapha, L. Mohamed, and K. Ali, "Comparative study of optimization techniques in deep learning: Application in the ophthalmology field," *Journal of Physics: Conference Series*, vol. 1743, no. 1, p. 012002, jan 2021, doi: 10.1088/1742-6596/1743/1/012002.
- [13] S. S. W. Su and S. L. Kek, "An Improvement of Stochastic Gradient Descent Approach for Mean-Variance Portfolio Optimization Problem," *Journal of Mathematics*, vol. 2021, pp. 1–10, mar 2021, doi: 10.1155/2021/8892636.
- [14] A. Hikmah, "Peramalan Deret Waktu Menggunakan Autoregressive (AR), Jaringan Syaraf Tiruan Radial Basis Function (RBF), dan Hibrid AR-RBF pada Inflasi Indonesia," *J. of Math.*, vol. 7, no. 2, pp. 1–14, 2013, doi: 10.15294/UJM.V7I2.13987.
- [15] A. F. Achmalia, W. Walid, and S. Sugiman, "Peramalan Penjualan Semen Menggunakan Backpropagation Neural Network dan Recurrent Neural Network," *J. of Math.*, vol. 9, no. 1, pp. 1–16, 2020, doi: 10.15294/UJM.V9I1.29970.
- [16] H. N. I. Hardiantho, "Analisis dan Implementasi Differential Evolution dan Recurrent Neural Network untuk Prediksi Data Time Series Studi Kasus Kurs Jual Emas," Skripsi, Universitas Telkom, 2011.
- [17] V. Nair and G. E. Hinton, "Rectified linear units improve restricted boltzmann machines," in *27th International Conference on Machine Learning (ICML-10)*, 2010, pp. 807–814.
- [18] K. K. Chandriah and R. V. Naraganahalli, "RNN / LSTM with modified Adam optimizer in deep learning approach for automobile spare parts demand forecasting," *Multimedia Tools and Applications*, vol. 80, no. 17, pp. 26 145–26 159, jul 2021, doi: 10.1007/s11042-021-10913-0.
- [19] S. Mandt, M. D. Hoffman, and D. M. Blei, "Stochastic Gradient Descent as Approximate Bayesian Inference," *J. of Mach. Learn. Res.*, vol. 18, no. 1, pp. 1–35, 2017, doi: 10.48550/arXiv.1704.04289.
- [20] C. Chen, N. Ding, and L. Carin, "On the convergence of stochastic gradient MCMC algorithms with high-order integrators," in *Proceedings of the 28th International Conference on Neural Information Processing Systems*, 2015, pp. 2269–2277.
- [21] A. Asrirawan, A. Seppewali, and N. Fitriyani, "Model Time Series untuk Prediksi Jumlah Kasus Infeksi Coronavirus (Covid-19) di Sulawesi Selatan," *Jurnal MSA (Matematika dan Statistika serta Aplikasinya)*, vol. 8, no. 2, pp. 77–82, dec 2020, doi: 10.24252/msa.v8i2.17427.
- [22] H. Haslina, H. Hasmah, K. W. Fitriani, M. Asbar, and A. Asrirawan, "Penerapan Metode ARIMA (Autoregressive Integrated Moving Average) Box Jenkins Untuk Memprediksi Pertambahan Jumlah Penduduk Transmigran (Jawa dan Bali) di Kecamatan Sukamaju, Kabupaten Luwu Utara Propinsi Sulawesi Selatan," *Dinamika*, vol. 9, no. 1, pp. 55–67, 2018.
- [23] A. Asrirawan, Rahmawati, Hikmah, and M. Abdy, "Spatial Econometric Model for Mapping Poverty Area in West Sulawesi," *Journal of Physics: Conference Series*, vol. 1752, no. 1, p. 012048, feb 2021, doi: 10.1088/1742-6596/1752/1/012048.
- [24] A. Asrirawan, S. U. Permata, and M. I. Fauzan, "Pendekatan Univariate Time Series Modelling untuk Prediksi Kuartalan Pertumbuhan Ekonomi Indonesia Pasca Vaksinasi COVID-19," *Jambura Journal of Mathematics*, vol. 4, no. 1, pp. 86–103, jan 2022, doi: 10.34312/jjom.v4i1.11717.



This article is an open-access article distributed under the terms and conditions of the [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/). Editorial of JJoM: Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B.J. Habibie, Moutong, Tilongkabila, Kabupaten Bone Bolango, Provinsi Gorontalo 96554, Indonesia.