

Prediksi Pemanasan Global di Provinsi Kalimantan Timur Menggunakan SARIMAX dan Neural Network

Saniyyah Sri Nurhayati^{a1}, Alif Fitriatul Khasanah^{a2}, Daradinanti Aulia Revanadilla^{a3}, Tsabit Bintang Herindra^{a4}, Fitri Kartiasih^{b5}

^{a1,a2,a3,a4}Program Studi DIV Komputasi Statistik, Politeknik Statistika STIS

^{b5}Program Studi DIV Statistika, Politeknik Statistika STIS

Jalan Otto Iskandardinata No.64C Jakarta 13330, Indonesia

¹ 222112351@stis.ac.id

² 222111874@stis.ac.id

³ 222111978@stis.ac.id

⁴ 222112402@stis.ac.id

⁵ fkartiasih@stis.ac.id

Abstrak

Pemindahan ibu kota negara dari DKI Jakarta ke Provinsi Kalimantan Timur akan mendorong terjadinya pembangunan besar-besaran yang akan berdampak pada berbagai bidang termasuk lingkungan dan perubahan iklim yang merupakan salah satu indikasi terjadinya pemanasan global. Penelitian ini bertujuan untuk membandingkan metode peramalan pemanasan global menggunakan Seasonal Autoregressive Integrated Moving Average with Exogenous Factors (SARIMAX) dan Neural Network Autoregressive with Exogenous Factors (NNARX) serta mengetahui proyeksi kondisi pemanasan global di Provinsi Kalimantan Timur. Hasil dari penelitian ini menunjukkan bahwa metode NNARX lebih baik dibandingkan dengan metode SARIMAX dalam memprediksi pola pemanasan global berdasarkan nilai RMSE, MAE, dan MAPE. Hal tersebut diduga karena tidak ada ketentuan yang pasti mengenai penentuan ordo pada model SARIMAX sehingga pemilihan model mengandung bias. Berdasarkan hasil prediksi yang diperoleh, suhu permukaan bumi di Provinsi Kalimantan Timur diprediksi akan meningkat pada tahun 2025.

Kata kunci: SARIMAX, NNARX, Pemanasan Global, Kalimantan Timur

Predicting Global Warming in East Kalimantan Province Using SARIMAX and Neural Network

Abstract

The move of the country's capital from DKI Jakarta to East Kalimantan Province will encourage massive development, which will have an impact on various fields, including the environment and climate change which is an indication of global warming. This research aims to compare global warming forecasting methods using Seasonal Autoregressive Integrated Moving Average with Exogenous Factors (SARIMAX) and Neural Network Autoregressive with Exogenous Factors (NNARX) and determine the projected global warming conditions in East Kalimantan Province. The results of the research show that the NNARX method is better than the SARIMAX method in predicting global warming patterns based on RMSE, MAE, MAPE, and MASE values. This result is suspected because there are no definite provisions regarding determining the order in the SARIMAX model so that the model selection contains bias. Based on prediction results, the earth's surface temperature in East Kalimantan Province is predicted to increase in 2025.

Keywords: SARIMAX, NNARX, Global Warming, East Kalimantan

I. PENDAHULUAN

Seiring berjalannya waktu, keadaan bumi telah mengalami beberapa kali perubahan. Peningkatan suhu permukaan bumi dalam jangka waktu yang lama disebut sebagai perubahan iklim global, atau pemanasan global. Kondisi tersebut merupakan akibat dari pembakaran

bahan bakar fosil seperti batu bara, minyak, dan gas, emisi gas rumah kaca—terutama karbon dioksida—meningkat, sehingga menyebabkan pemanasan global [1]. Rata-rata suhu permukaan dunia mencapai 1,21°C pada tahun 2021 dibandingkan dengan suhu pra-industri (rata-rata tahun 1850–1900), sedangkan rata-rata permukaan laut global naik sebesar 82 mm dari rata-rata tahun 1986–2005 [2].

Dengan demikian, pemanasan global dapat diartikan sebagai suatu kondisi dimana suhu permukaan bumi, udara, dan permukaan laut meningkat secara terus menerus dari waktu ke waktu. Meskipun kenaikan suhu global tergolong kecil, namun dapat memberikan dampak yang sangat besar terhadap hilangnya keanekaragaman spesies laut [3] dan berbagai dampak lainnya. Oleh karena itu, pemahaman dan pengetahuan yang komprehensif mengenai pemanasan global, penyebab, dan dampaknya terhadap kehidupan di bumi sangat penting untuk menemukan mitigasi yang tepat.

Faktor yang berkontribusi terhadap pemanasan global adalah peningkatan emisi CO₂. EPPO (2013) mendefinisikan emisi CO₂ sebagai jumlah gas rumah kaca (CO₂) yang dilepaskan selama penggunaan energi. Emisi CO₂ mengalami peningkatan dari tahun ke tahun, dari 141 juta ton menjadi 327 juta ton pada tahun 1990 hingga 2010 [4]-[6]. Artinya jumlah emisi CO₂ pada tahun 2010 meningkat sebesar 131,92% dibandingkan tahun 1990 atau sekitar 186 juta ton. Hal ini disebabkan semakin meningkatnya penggunaan kendaraan bermotor dan berbagai perangkat lain yang mengeluarkan CO₂ selama pengoperasiannya.

Selain emisi CO₂, perubahan iklim mencakup berbagai aspek, antara lain perubahan suhu, pola cuaca, peningkatan suhu laut, pencairan es, dan lain sebagainya yang disebabkan oleh tingginya emisi karbon monoksida (CO). Emisi CO merupakan salah satu komponen yang mempengaruhi tingkat pemanasan global secara tidak langsung. Menurut Thompson (1992), karena karbon monoksida (CO) merupakan penyerap radikal hidroksil troposfer yang signifikan, hal ini berdampak pada umur gas rumah kaca lainnya, termasuk metana (CH₄) [7]. Gas-gas utama yang membentuk gas rumah kaca di atmosfer termasuk karbon dioksida, uap air, metana, dinitrogen oksida, dan ozon [8]. Beberapa gas tersebut menimbulkan efek rumah kaca yang mengakibatkan radiasi matahari tidak dipantulkan kembali ke luar bumi sehingga menyebabkan sebagian panas matahari terbatas pada bumi. Panas matahari yang terbatas ini berdampak pada peningkatan suhu bumi dan akan berdampak pada pemanasan global.

Dampak pemanasan global antara lain perubahan iklim ekstrem seperti gelombang panas yang lebih hebat, badai tropis, dan musim hujan yang tidak teratur. Perubahan iklim yang merupakan salah satu bentuk pemanasan global juga berdampak pada ekosistem di darat dan laut [9]. Variasi suhu dan perubahan pola curah hujan merupakan dua indikator lebih lanjut dari perubahan iklim. Kelestarian flora dan fauna mungkin terancam oleh hal ini, dan perubahan habitat beberapa spesies dapat menempatkan mereka pada risiko kepunahan. Selain menyebabkan kerusakan pada kondisi bumi, perubahan iklim juga menjadi pemicu terjadinya peristiwa cuaca ekstrem yang merusak infrastruktur [10], seperti banjir, badai, dan kekeringan. Perubahan iklim juga dapat mempengaruhi pola curah hujan dan menyebabkan kekeringan di beberapa daerah sehingga menyebabkan krisis air bersih. Selain itu, pemanasan global dapat menyebabkan mencairnya lapisan es di kutub dan

mengakibatkan naiknya permukaan air laut [11], yang kemungkinan akan menenggelamkan pulau-pulau kecil, wilayah pesisir, dan kota-kota dataran rendah.

Dari sudut pandang kesehatan, pemanasan global dipandang sebagai suatu kondisi yang dapat mempengaruhi kesehatan manusia [12] melalui meningkatnya penyakit yang ditularkan melalui vektor (seperti nyamuk pembawa malaria), kekurangan pangan, dan ancaman terhadap pasokan air bersih. Keadaan yang berhubungan dengan pemanasan global seperti kenaikan suhu dan perubahan pola curah hujan dapat mengganggu produksi pangan dan menurunkan hasil pertanian, sehingga menyebabkan krisis pangan di beberapa daerah [13]. Dari segi lingkungan, pemanasan global dapat menyebabkan kerusakan langsung terhadap lingkungan, termasuk hutan, lahan basah, dan terumbu karang, yang dapat mengancam keanekaragaman hayati dan menyebabkan hilangnya ekosistem secara signifikan. Ref [14] menyebutkan bahwa pemanasan global juga dapat mempengaruhi kemampuan menghasilkan prakiraan cuaca yang akurat.

Saat ini terdapat 38 provinsi di Indonesia, salah satunya adalah Kalimantan Timur. Ke depannya, direncanakan pemindahan ibu kota negara dari Provinsi DKI Jakarta ke Provinsi Kalimantan Timur. Pemindahan ibu kota akan menimbulkan pembangunan besar-besaran yang berdampak pada perubahan kondisi lingkungan, termasuk perubahan iklim [15]. Sehingga, diperkirakan akan terjadi lonjakan suhu global di Provinsi Kalimantan Timur akibat pemindahan ibu kota negara. Oleh karena itu, memahami pola pemanasan global secara keseluruhan sangat penting untuk memutuskan langkah apa yang harus diambil untuk mengurangi dampak yang terjadi [16].

Prediksi pemanasan global sering kali dibuat dengan menggunakan penginderaan jauh, baik secara mandiri maupun bersama dengan teknik lain. Para peneliti [17]-[18] telah menggunakan penginderaan jauh bersama dengan Peta LULC dan analisis spasial. Studi tersebut menghasilkan ketepatan yang tinggi dalam memprediksi global warming. Penilaian dan peramalan iklim global yang berubah dengan cepat sangat terbantu dengan penggunaan model komputasi lunak yang memprediksi perubahan Suhu Permukaan Tanah (LST). Empat teknik soft computing diterapkan dan dibandingkan dalam penelitian oleh [19] untuk menentukan model terbaik yang dapat digunakan untuk memprediksi perubahan suhu permukaan tanah di wilayah Beijing: Multivariate Adaptive Regression Splines (MARS), Wavelet Neural Network (WNN), Sistem Inferensi Neurofuzzy Adaptif (ANFIS), dan Sistem Inferensi Neurofuzzy Berkembang Dinamis (DENFIS). Pada tahap pelatihan dan pengujian, keempat model dievaluasi menggunakan analisis statistik, koefisien determinasi (R^2), Root Mean Square Error (RMSE), dan Mean Absolute Error (MAE). Hasil dari model-model tersebut menunjukkan bahwa suhu permukaan tanah di daerah penelitian dapat diprediksi dengan menggunakan model MARS, ANFIS, dan DENFIS. Sedangkan Multivariate Adaptive Regression Splines (MARS) digunakan untuk mengestimasi variabel-

variabel penting yang harus dipertimbangkan dalam model desain.

Prediksi pemanasan global adalah bidang yang banyak dilakukan dengan menggunakan *machine learning*. Studi [20] menggunakan *machine learning* untuk membuat model prediksi perubahan suhu global. Selain itu, terdapat beberapa metode yang juga dipertimbangkan: Random Forest, Extra Tree, K-Nearest Neighbors, Gradient Boosting Machine, Light Gradient Boosting Machine, dan Bayesian Ridge diselidiki untuk membuat model prediksi perubahan suhu global dengan kriteria evaluasi Mean Absolute Error (MAPE), Mean Square Error (MSE), Root Mean Square Error (RMSE), koefisien determinasi (R^2), Root Mean Squared Logarithmic Error (RMSLE), dan Mean Absolute Percentage Error (MAPE). Seperti yang dapat dilihat dari temuannya, algoritma Extra Trees memiliki kinerja terbaik dalam memperkirakan perubahan suhu global.

Saat ini masih terbatas penelitian yang menggunakan analisis *time series* untuk memprediksi pemanasan global. Oleh karena itu, pada penelitian ini pendekatan analisis *time series* akan digunakan dalam pemodelan data Suhu Permukaan Tanah (LST). Seasonal autoregressive integrated moving average with exogenous factors (SARIMAX) dipilih karena merupakan model peramalan deret waktu yang lebih baik daripada ARIMA karena memasukan unsur musiman dan faktor eksogen. Bahkan dalam kasus ketika panjang kumpulan data input dan output hampir sama dan mengarah ke arah yang sama, model SARIMAX dapat mengurangi nilai kesalahan dan meningkatkan akurasi secara keseluruhan [21]. Di sisi lain, model NNARX merupakan model *machine learning* yang digunakan untuk peramalan deret waktu karena model NNARX telah berhasil digunakan untuk menggambarkan hubungan input-output dari banyak sistem yang kompleks [22]. Oleh karena itu, penelitian ini bertujuan untuk mengetahui prediksi kondisi pemanasan global di Provinsi Kalimantan Timur serta mengisi kekosongan penelitian yang memprediksi pemanasan global dengan analisis *time series*, SARIMAX, yang kemudian hasilnya dibandingkan dengan metode *machine learning* yaitu NNARX. Penelitian ini berupaya untuk menentukan model mana yang optimal untuk memprediksi data deret waktu pemanasan global di Provinsi Kalimantan Timur.

II. METODOLOGI

A. Tinjauan Teoritis

- 1) *Suhu Permukaan Tanah (LST)*: Suhu termodinamika lapisan tipis pada permukaan tanah, tumbuhan, atau komponen permukaan lainnya, serta atmosfer, disebut sebagai “suhu permukaan tanah” [23]. Pengukuran suhu permukaan bumi pada saat disentuh dikenal dengan istilah suhu permukaan tanah (LST), sebagaimana dinyatakan dalam [24]. Dengan kata lain, suhu permukaan tanah mengacu pada rekaman suhu permukaan bumi di suatu wilayah tertentu. Karena terdapat korelasi yang kuat antara pemanasan global dan suhu permukaan bumi, pengukuran LST menjadi hal yang krusial

[25]. Hal ini menyiratkan bahwa pengukuran dan analisis LST merupakan salah satu metode yang dapat digunakan untuk menilai atau mengukur pemanasan global. Badan Penerbangan dan Antariksa Nasional (NASA) telah mengidentifikasi LST sebagai parameter permukaan bumi yang kritis, dan Program Ilmu Perubahan Iklim AS telah mengidentifikasinya sebagai salah satu dari sepuluh faktor iklim utama [26]. Satu-satunya metode yang tersedia untuk mengukur LST secara global pada skala piksel rata-rata spasial adalah observasi satelit, yang menggunakan cakupan area luas dan kunjungan ulang berulang kali [27].

- 2) *Emisi karbon*: Ukuran jumlah total gas rumah kaca yang dilepaskan ke atmosfer, baik secara langsung maupun tidak langsung, melalui barang, peristiwa, atau organisasi disebut emisi karbon. Karbon dioksida, yang sebagian besar dihasilkan dari pembakaran bahan bakar fosil untuk transportasi, pemanasan, dan listrik, merupakan salah satu gas rumah kaca utama yang biasanya dihasilkan oleh aktivitas manusia, menurut [28]. Saat ini, dua hal yang menyebabkan perubahan iklim dan pemanasan global adalah emisi gas rumah kaca dan karbon. Indonesia menempati peringkat kedelapan dunia dalam hal emisi karbon yang dihasilkan, menurut World Resource Institute (2018). Emisi gas karbon dioksida (CO₂) baik dari aktivitas manusia langsung maupun tidak langsung disebut sebagai emisi karbon, dan dinyatakan dalam ton [29]–[30]. Faktor yang berkontribusi terhadap timbulnya emisi karbon tidak hanya penggunaan bahan bakar fosil tetapi juga penggunaan perangkat teknologi. Journal of Cleaner Production memproyeksikan bahwa ICT (teknologi informasi dan komputer) akan menyumbang 14% emisi karbon global pada tahun 2040, naik dari 3,5% pada tahun 2020 dan sekitar 1% pada tahun 2007.
- 3) *Rata-Rata Pergerakan Terintegrasi Autoregresif Musiman dengan Faktor Eksogen (SARIMAX)*: George EP Box dan Gwilym M. Jenkins menciptakan model Autoregressive Integrated Moving Average (ARIMA), yang populer disebut sebagai model Box-Jenkins [31]. Model yang digunakan dalam peramalan deret waktu disebut Rata-Rata Pergerakan Terintegrasi Autoregresif Musiman, atau SARIMA. Meskipun memiliki komponen rata-rata bergerak dan autoregresif untuk memperhitungkan pengaruh data musiman, model ini sebanding dengan model ARIMA [32]. Pada tahun 1987, Bierens menerbitkan sebuah penelitian yang awalnya menyajikan model Seasonal Autoregressive Integrated Moving Average with Exogenous Factors (SARIMAX) [33]. SARIMAX merupakan model yang dibuat dengan menggabungkan faktor musiman, variabel

eksogen, atau data luar dengan ARIMA dan SARIMA. Dalam hal memprediksi ruang data yang rumit dengan siklus, SARIMAX jauh lebih efektif dibandingkan ARIMA karena menggabungkan musiman sebagai parameter dan memasukkan elemen eksogen ke dalam pemodelan. Persamaan SARIMAX adalah ARIMA(p,d,q)(P,D,Q)m, dimana p, d, dan q masing-masing mewakili komponen autoregresif, diferensiasi, dan rata-rata bergerak, dan P, D, dan Q singkatan dari komponen musiman model. Banyaknya periode pada setiap musim dilambangkan dengan m. Menurut studi [34], karena SARIMAX memperhitungkan musiman sebagai parameter, kinerjanya jauh lebih baik daripada ARIMA ketika memperkirakan ruang data yang rumit dengan musiman.

- 4) *Autoregresif Jaringan Syaraf Tiruan dengan Faktor Eksogen (NNARX)*: Salah satu pendekatan pemecahan masalah yang mengambil inspirasi dari otak manusia adalah Jaringan Syaraf Tiruan (JST) [35]. ANN adalah fungsi matematika. ANN adalah suatu pendekatan yang mensimulasikan fungsi sistem saraf biologis, menurut [36]. Tiga lapisan—lapisan masukan, lapisan tersembunyi, dan lapisan keluaran—terdiri dari neuron-neuron terkait yang membentuk arsitektur jaringan saraf tiruan. Estimasi fungsional, prediksi, optimasi, dan klasifikasi adalah beberapa tugas yang digunakan ANN [37] – [39]. Neural Net Autoregressive with Exogenous Input (NNARX) merupakan salah satu kemajuan dalam ANN. Bentuk ANN yang disempurnakan yang disebut NNARX, menurut [40], dirancang untuk mengatasi masalah nonlinier yang tidak dapat ditangani oleh ANN. Banyak disiplin ilmu telah memanfaatkan NNARX secara ekstensif, termasuk pengenalan suara, deteksi kesalahan, dan prediksi banjir [41]-[43].
- 5) *Ukuran Akurasi Prakiraan*: Keakuratan peramalan inilah yang menentukan seberapa baik model prediksi dievaluasi. Standar berikut dapat menjadi landasan untuk mengevaluasi keakuratan prediksi model guna memastikan keakuratannya [44].

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \tag{1}$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \tag{2}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \tag{3}$$

dimana n adalah banyaknya prediksi, merupakan nilai hasil ramalan, dan merupakan nilai sebenarnya. Model yang baik untuk memprediksi adalah model yang memberikan nilai terendah di seluruh kriteria [45]. $\hat{Y}_t Y_t$

- 6) *Pemeriksaan Kebisingan Putih*: White noise didefinisikan sebagai data deret waktu dengan varian konstan dan kumpulan observasi yang tidak berkorelasi [46]. Dalam skenario ini, plot

fungsi autokorelasi (ACF) dan fungsi autokorelasi parsial (PACF) dapat digunakan untuk menguji white noise pada data deret waktu. $\epsilon_t \sim^{iid} (0, \sigma^2)$

- 7) *Augmented Dickey–Fuller (ADF) Test*: Suatu uji yang digunakan untuk menentukan apakah kumpulan data stasioner atau tidak [47]. Ketika dalam kondisi data non-stasioner, diferensiasi tingkat tinggi dapat diterapkan untuk membuat data menjadi stasioner. Hasil ADF dievaluasi berdasarkan dua jenis nilai: nilai statistik dan nilai p-value. Nilai statistik negative menyebabkan penolakan kuat terhadap hipotesis nol tentang akar unit, yang menunjukkan bahwa deret waktu tidak memiliki akar unit sehingga stasioner. Sedangkan nilai statistik positif, maka hipotesis nol tentang akar unit tidak ditolak, yang menunjukkan bahwa deret waktu mempunyai akar unit sehingga tidak stasioner [48]. Selain itu, jika p-value ≤ tingkat signifikansi, data tidak mengandung akar unit atau data stasioner dan jika p-value > 0,05, berarti deret waktu rata-rata mengandung akar unit, hipotesis nol tidak ditolak, dan data tidak stasioner [49].

B. Data dan Metode

Terdapat tiga sumber data yang digunakan dalam penelitian ini, yaitu: (i) Data Suhu Permukaan Daratan di Kalimantan Timur diperoleh dari National Aeronautics and Space Administration (NASA) Amerika Serikat, (ii) data konsentrasi gas CO sebagai emisi karbon yang diperoleh dari Stasiun Pemantauan Atmosfer Global (GAW) Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), dan (iii) data konsentrasi gas CO dari Stasiun Pemantauan Atmosfer Global (GAW) Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Ketiga data tersebut merupakan data dengan periode bulanan mulai dari bulan Februari 2003 hingga bulan Desember 2022. Lokus yang diambil pada penelitian ini adalah Provinsi Kalimantan Timur. Keterbatasan dalam penelitian ini adalah data yang tersedia pada National Aeronautics and Space Administration (NASA) Amerika Serikat dan Stasiun Pemantauan Atmosfer Global (GAW) Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) hanya sampai tahun 2022 sehingga kondisi tersebut tidak bisa mencerminkan kondisi saat ini.

- 1) *Rata-Rata Pergerakan Terintegrasi Autoregresif Musiman dengan Faktor Eksogen (SARIMAX)*: Model SARIMAX merupakan pengembangan dari model SARIMA yang ditingkatkan dengan kemampuan untuk mengintegrasikan variabel eksogen atau variabel penjelas [50]. Penambahan variabel eksogen dapat membuat model yang dihasilkan menjadi lebih baik dibandingkan dengan model tanpa variabel eksogen. Rumus model SARIMAX bergantung pada struktur model. Model SARIMAX(p,d,q)(P,D,Q)s memiliki bentuk umum sebagai berikut [51].

$$\phi_p(G)\phi_p(G^{seasonal})(1-G)^d(1-G^{seasonal})^D X_t = \alpha_k y_{k,t} + \gamma_q(G)\omega_q(G^{seasonal})e_t \quad (4)$$

Dimana $\phi_p(G)$ dan $\gamma_q(G)$ mengindikasikan ordo dari komponen *non-seasonal autoregressive* (AR) dan *non-seasonal moving average* (MA), $\phi_p(G^{seasonal})$ dan $\omega_q(G^{seasonal})$ mengindikasikan ordo dari komponen *seasonal autoregressive* (SAR) dan *seasonal moving average* (SMA), $(1-G)^d$ dan $(1-G^{seasonal})^D$ mengindikasikan komponen *non-seasonal* dan *seasonal differencing*, serta $y_{k,t}$ merupakan variabel eksogen ke-k pada waktu t dan α_k merupakan nilai koefisien korelasi dari variabel eksogen ke-k. Metode yang digunakan untuk menghasilkan model adalah sebagai berikut [48].


- a) Tahap pertama, menentukan ordo *differencing* dengan mempertimbangan data runtun waktu mencapai keadaan stasioner.
- b) Tahap kedua, penentuan model tentatif yang dilakukan dengan cara memilih ordo AR dan MA dalam menentukan parameter model berdasarkan diagram ACF dan PACF.

Nilai Akaike information criterion dan Schwarz Bayesian criterion digunakan untuk menilai kinerja model tentatif terbaik. Nilai AIC dan BIC yang relatif rendah menunjukkan kecocokan model terbaik [52]. Terdapat kemungkinan bias pada model SARIMAX karena pada faktanya, prosedur penentuan komponen AR dan MA menggunakan penilaian pribadi dan tidak ada aturan jelas tentang bagaimana memutuskan komponen AR dan MA yang sesuai [53].

- 2) *Autoregresif Jaringan Neural dengan Input Eksogen (NNARX)*: Model jaringan saraf tiruan (JST) adalah jenis model jaringan saraf yang digunakan untuk mensimulasikan hubungan antara variabel masukan dan keluaran data deret waktu. Kemajuan dari ANN adalah pendekatan Neural Network Autoregressive dengan input eksogen (NNARX), yang digunakan untuk menangani masalah non linier yang tidak dapat diselesaikan oleh ANN. NNARX terhubung ke jaringan dinamis multi-layer melalui umpan balik. Rumus umum dan algoritma NNARX dijelaskan sebagai berikut berdasarkan Ref [54].

$$y'(t) = F(y'(t-1), \dots, y'(t-n_y), x(t-1), \dots, x(t-n_x)) \quad (5)$$


Dimana akan diregresi dengan nilai keluaran dan masukan sebelumnya, F sebagai fungsi non linier yang menghubungkan nilai dengan nilai keluaran sebelumnya, dan sebagai masukan eksogen pada waktu t. Arsitektur standar NNARX dapat didefinisikan sebagai arsitektur loop tertutup di mana keluaran jaringan diumpungkan kembali sebagai masukan ke Jaringan Feed Forward. $y'(t)y'(t)x(t)$



Gambar 1. Arsitektur loop tertutup NNARX

Kombinasi masukan dengan masukan sebelumnya dan umpan balik dari nilai prediksi masa lalu dalam rangkaian waktu digunakan sebagai prediksi. Seperti yang digambarkan pada persamaan berikut: $x(t)x(t-n_y, y'(t))$

$$y'(t+1) = F(y'(t), y'(t-1), \dots, y'(t-n_y), x(t), x(t-1), \dots, x(t-n_x)) \quad (6)$$



Gambar 2. Kombinasi nilai masukan dan umpan balik $x(t)y(t)$

Peramalan nilai masa depan dapat dilakukan dengan menggabungkan nilai $x(t)$ sekarang dan masa lalu dengan nilai inkremental masa lalu yang telah diuji atau dituliskan secara matematis sebagai berikut.


$$y'(t+1) = F(y''(t), y'(t-1), \dots, y'(t-n_y), x(t), x(t-1), x(t-n_x)) \quad (7)$$

Fase pelatihan jaringan harus dilakukan beberapa kali untuk memperoleh hasil yang optimal [55].

III. HASIL DAN DISKUSI

A. Rata-Rata Pergerakan Terintegrasi Autoregresif Musiman dengan Faktor Eksogen (SARIMAX)

Langkah pertama dalam membentuk model SARIMAX adalah mengamati pola data asli dengan menggunakan diagram garis. Berikut visualisasi data Suhu Permukaan Tanah (LST) Provinsi Kalimantan Timur periode Februari 2013 hingga Desember 2022.




Gambar 3. Plot data suhu permukaan Kalimantan Timur

Data LST Provinsi Kalimantan Timur periode Februari 2013 hingga Desember 2022 mempunyai tren musiman, terlihat dari hasil plot di atas. Plot data pada Gambar 3 juga menunjukkan bahwa pola data LST Provinsi Kalimantan Timur mempunyai perilaku nonstasioner baik pada mean maupun variance datanya. Stasioneritas dapat diketahui melalui pola grafik yang tidak konstan dan terdapat fluktuasi pada waktu-waktu tertentu. Pengujian formal, seperti Augmented Dickey-Fuller Test (ADF-test), dapat digunakan untuk memverifikasi stasioneritas data selain mencari pola pada grafik. Jika kumpulan data tidak stabil, tes formal yang disebut tes ADF dapat digunakan untuk mengetahuinya. Berikut uji ADF data Suhu Permukaan Tanah Provinsi Kalimantan Timur dengan taraf signifikansi 5% atau 0,05.

TABEL I. UJI ADF DI LEVEL

Uji Stasioner	Nilai kritis	nilai p
Perbedaan musiman uji ADF	-2.5309	0,3561

Data suhu permukaan tanah di Provinsi Kalimantan Timur tidak stasioner, hal ini ditunjukkan dari hasil uji Augmented Dickey-Fuller (ADF) pada Tabel 1. Nilai p-value yang dihasilkan menunjukkan hasil yang lebih tinggi dari tingkat signifikansi yang dipilih, 5%. Prosedur pembedaan musiman digunakan untuk mengatasi data LST yang tidak stasioner, dan plot data baru yang dihasilkan terlihat seperti pada gambar berikut.



Gambar 8. Plot hasil perbedaan musiman data LST Kalimantan Timur


Plot data di atas menggambarkan pola yang konstan baik rata-rata maupun variansnya. Namun untuk memperkuat kesimpulan yang diambil, perlu dilakukan pengujian formal terhadap LST setelah dilakukan prosedur pembedaan musiman yang menghasilkan keluaran pada Tabel 2.

TABEL II. UJI ADF SETELAH SEASONAL DIFFERENCING


Uji Stasioner	Nilai kritis	nilai p
Uji ADF <i>Seasonal Differencing</i>	-5,0855	0,01

*) Tingkat signifikansi = 0,05

Nilai p-value yang lebih kecil dari ambang batas signifikansi menunjukkan bahwa data Suhu Permukaan Tanah Provinsi Kalimantan Timur stasioner sesuai dengan temuan uji Augmented Dickey-Fuller (ADF) pada Tabel 2. Berikut adalah grafik yang menampilkan temuan tersebut plot ACF dan PACF.



Gambar 5a. Plot ACF setelah perbedaan musiman



Gambar 5b. Plot PACF setelah perbedaan musiman

Beberapa model SARIMAX potensial diturunkan dari hasil plot ACF dan PACF pada Gambar 5. Pola ACF yang menurun secara perlahan dan PACF yang memiliki *spike* pada beberapa lag menunjukkan bahwa model memiliki ordo pada AR. Grafik PACF digunakan dalam penentuan ordo *Autoregressive* (AR). Pada Gambar 5b menunjukkan hasil bahwa terdapat garis yang melebihi garis batas (*spike*) yaitu pada lag 1, 2, 3, dan 5. Sehingga ordo dari AR *non seasonal* yang digunakan adalah 1, 2, 3, dan 5. Grafik tersebut juga digunakan untuk mengidentifikasi AR pada *seasonal*. Tidak terlihat adanya *spike* pada lag ke 12 sehingga mengindikasikan tidak adanya komponen AR pada *seasonal*. Tabel 3 merupakan beberapa kemungkinan

No	SARIMAX (p,d,q)(P,D,Q) ₁₂	AIC	BIC
1	SARIMAX(1,0,0)(0,1,0) ₁₂	147,226	157,917
2	SARIMAX(2,0,0)(0,1,0) ₁₂	148,084	161,448
3	SARIMAX(3,0,0)(0,1,0) ₁₂	149,553	165,590
4	SARIMAX(5,0,0)(0,1,0) ₁₂	153,490	174,872

model yang terbentuk. Kriteria informasi Bayesian (BIC) dan Akaike Information Criterion (AIC) akan digunakan untuk mengevaluasi dan membandingkan performa masing-masing model. Keempat model potensial tersebut memiliki nilai BIC dan AIC yang relatif sama sehingga keempat model tersebut akan masuk ke tahap selanjutnya yaitu pengujian asumsi. Asumsi yang diperlukan adalah asumsi *white noise*. Pemilihan model yang memenuhi asumsi *white noise* dilihat dari uji Ljung Box dan Jarque-Bera. Model yang memenuhi asumsi memiliki nilai p-value lebih dari 0,05 (taraf signifikansi) untuk kedua uji tersebut. Sehingga dari keempat model pada Tabel 4 diperoleh bahwa model 3 dan 5 memenuhi asumsi *white noise* dengan nilai peluang di bawah ini.

TABEL IV. NILAI PROBABILITAS WHITE NOISE

Model	p-value Uji Ljung Box	p-value Uji Jarque-Bera
SARIMAX(1,0,0)(0,1,0) ₁₂	0,41	0,00
SARIMAX(2,0,0)(0,1,0) ₁₂	1,00	0,03
SARIMAX(3,0,0)(0,1,0) ₁₂	0,94	0,07
SARIMAX(5,0,0)(0,1,0) ₁₂	0,95	0,09

Setelah melakukan eliminasi pada asumsi white noise. Selanjutnya pemilihan model dilakukan dengan nilai akurasi yaitu RMSE, MAE, MAPE. Semakin rendah nilai kriteria tersebut maka semakin baik model yang dihasilkan. Dari seluruh ukuran tersebut, model SARIMAX(3,0,0)(0,1,0)₁₂ dipilih sebagai model yang akan digunakan untuk forecasting karena memiliki nilai yang RMSE, MAE, MAPE yang lebih kecil dibandingkan dengan model SARIMAX(5,0,0)(0,1,0)₁₂.

B. Autoregresif Jaringan Syaraf Tiruan dengan Input Eksogen (NNARX)


Pembentukan model NNARX terdiri dari Neural Network (NN) dan Autoregressive (AR) dimana NN dibentuk dengan lapisan-lapisan dalam jaringan saraf dan AR terdiri dari AR non-musiman dan AR musiman. Lapisan masukan, lapisan tersembunyi, dan lapisan keluaran adalah tiga lapisan yang membentuk jaringan saraf. Model NNARX pada penelitian ini menggunakan data Suhu Permukaan Tanah sebagai variabel Y (terikat) dan data karbon dioksida dan karbon monoksida sebagai faktor X eksogen. Penyusunan model NNARX ini terdiri dari 4 lapisan masukan, 1 lapisan keluaran dan jumlah lapisan tersembunyi yang disesuaikan dengan model terbaik. Berikut pemodelan NNARX dengan 4 input layer dan 1 output layer. Tabel berikut menunjukkan nilai Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), dan Mean Absolute Scaled Error (MASE) untuk setiap struktur jaringan.

TABEL V. PERBANDINGAN BEBERAPA MODEL NNARX

No	Struktur Jaringan	RMSE	MAE	PETA	MAS
1	4-2-1	0,3636	0,2670	0,9325	0,4715
2	4-3-1	0,3117	0,2304	0,7967	0,4024
3	4-4-1	0,2823	0,2042	0,7067	0,3566
4	4-5-1	0,2387	0,1758	0,6085	0,3070
5	4-7-1	0,1934	0,1452	0,5033	0,2535
6	4-10-1	0,1263	0,0916	0,3181	0,1599
7	4-20-1	0,0448	0,0319	0,1107	0,0556
8	4-32-1	0,0199	0,0118	0,0409	0,0206

1	4-2-1	0,3636	0,2670	0,9325	0,4715
2	4-3-1	0,3117	0,2304	0,7967	0,4024
3	4-4-1	0,2823	0,2042	0,7067	0,3566
4	4-5-1	0,2387	0,1758	0,6085	0,3070
5	4-7-1	0,1934	0,1452	0,5033	0,2535
6	4-10-1	0,1263	0,0916	0,3181	0,1599
7	4-20-1	0,0448	0,0319	0,1107	0,0556
8	4-32-1	0,0199	0,0118	0,0409	0,0206

Berdasarkan hasil perbandingan pada Tabel 5 terlihat bahwa semakin banyak lapisan tersembunyi pada Neural Network (NN), maka semakin kecil pula Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), dan hasil Mean Absolute Scaled Error (MASE). Idealnya, ada satu atau dua level di lapisan tersembunyi NNARX untuk data yang sederhana dan dimensinya terbatas. Struktur tersembunyi NNARX yang lebih besar dapat meminimalkan kesalahan tetapi hal ini tidak baik untuk peramalan karena memungkinkan terjadinya overfitting pada data kereta. Dengan demikian, model NNARX terbaik untuk data Suhu Permukaan Tanah Provinsi Kalimantan Timur adalah NNARX 4-2-1 dengan Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), dan Mean Absolute Scaled Error (MASE) masing-masing bernilai 0,364, 0,27, 0,932, dan 0,471. Melalui model terbaik diperoleh plot peramalan sebagai berikut.



Gambar 8. Hasil peramalan model NNARX 4-2-1

Berdasarkan hasil peramalan dengan menggunakan model NNARX 4-2-1 yang ditunjukkan pada Gambar 8, dapat diperkirakan bahwa Suhu Permukaan Tanah di Provinsi Kalimantan Timur mengalami peningkatan hingga tahun 2025. Hal ini menunjukkan bahwa tingkat pemanasan global di Provinsi Kalimantan Timur berpeluang besar mengalami tren peningkatan hingga tahun 2025. Hal ini ditunjukkan dengan pola grafik berwarna biru yang lebih tinggi dibandingkan tingkat pemanasan global pada bulan Februari 2013 hingga Desember 2022 (hitam).

TABEL VI. PERBANDINGAN SARIMAX DAN NNARX

Kriteria	Model	
	SARIMAX(3,0,0)(2,1,0) ₁₂	NNARX 4-2-1
RMSE	0,4348734	0,363656

MAE	0,3136007	0,269984
MAPE	1,082548	0,471492

Tabel 6 diatas merupakan tabel perbandingan nilai RMSE, MAE, dan MAPE untuk model terbaik pada masing-masing metode. Model SARIMAX yang diusulkan adalah SARIMAX(3,0,0)(0,1,0)₁₂ dan model NNARX yang diusulkan adalah NNARX 4-2-1. Jika dibandingkan pada seluruh kriteria di atas, model dengan metode NNARX 4-2-1 memiliki nilai lebih kecil dibandingkan SARIMAX (3,0,0)(0,1,0)₁₂. Pemilihan metode terbaik antara SARIMAX dan NNARX dilihat dari Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE) terkecil. Karena pada umumnya, semakin besar nilai kriterianya, semakin besar pula ukurannya [56]. Sehingga diperoleh metode prediksi pemanasan global yang paling baik adalah metode NNARX karena nilai RMSE, MAE, dan MAPE, pada model NNARX 4-2-1 lebih kecil dibandingkan SARIMAX(3,0,0)(0,1,0)₁₂.

TABEL VII. PERBANDINGAN NILAI PREDIKSI SARIMAX DAN NNARX

Tanggal	SARIMAX (3,0,0)(2,1,0) ₁₂	NNARX 4-2-1
Januari 2023	27,9587	28,7897
Februari 2023	27,9143	28,9764
Maret 2023	28,6127	29,0173
April 2023	28,1151	28,6198
Mei 2023	28,7263	28,5489
Juni 2023	28,8229	28,5388
Juli 2023	28,6976	28,5323
Agustus 2023	28,2129	28,5138
September 2023	28,3457	28,5465
Oktober 2023	28,3188	28,5534
November 2023	28,5067	28,6455
Desember 2023	28,6706	28,9484
Januari 2024	28,2804	29,8586
Februari 2024	27,8867	29,1699
Maret 2024	28,4868	29,1049
April 2024	28,3442	27,9955
Mei 2024	28,9255	27,5007

Juni 2024	28,5575	27,9005
Juli 2024	28,3676	28,0741
Agustus 2024	28,3287	28,5885
September 2024	28,8230	30,2532
Oktober 2024	28,6339	29,5462
November 2024	28,6393	29,0396
Desember 2024	28,9077	29,7599
Januari 2025	28,5230	30,7990
Februari 2025	28,1019	30,2251
Maret 2025	28,6645	29,3060
April 2025	28,4557	28,2581
Mei 2025	29,0041	28,0152
Juni 2025	28,8294	28,5780
Juli 2025	29,1911	29,1801
Agustus 2025	29,6233	30,5314
September 2025	29,8957	31,3460
Oktober 2025	29,1405	30,7915
November 2025	28,7121	29,7548
Desember 2025	28,7870	29,4115

Tabel 7 menunjukkan bahwa hasil prediksi kedua model baik SARIMAX dan NNARX hampir identik. Jika dikaitkan dengan pemanasan global maka suhu permukaan bumi di Provinsi Kalimantan Timur cenderung meningkat pada tahun 2025 karena suhu pada tahun tersebut lebih besar dibandingkan dengan tahun tahun sebelumnya. Hal itu selaras dengan hipotesis bahwa pembangunan yang pesat di Provinsi Kalimantan Timur dapat mengakibatkan kenaikan suhu permukaan bumi. Oleh karena itu, proyeksi pemanasan global yang tepat diperlukan agar dapat menjadi landasan pengambilan keputusan.

IV. KESIMPULAN

Karena pemanasan global berdampak buruk terhadap lingkungan, kesehatan, ekonomi, dan infrastruktur, maka pemahaman yang baik tentang pola pemanasan global menjadi hal yang penting untuk diketahui. Pemandangan ibu kota negara ke Provinsi Kalimantan Timur bisa menyebabkan terjadinya pembangunan secara massif di provinsi tersebut. Perkembangan ini tentunya akan berdampak pada sejumlah masalah lingkungan hidup, termasuk perubahan iklim yang merupakan salah satu

indikasi terjadinya pemanasan global. Berkaitan dengan hal tersebut, diperlukan pemahaman yang komprehensif mengenai pola data pemanasan global agar mitigasinya dapat dilakukan dengan tepat.

Adapun pada penelitian ini peramalan pola pemanasan global dilakukan dengan menggunakan metode SARIMAX dan NNARX dengan tujuan untuk mengetahui metode mana yang lebih baik dalam meramalkan data pemanasan global. Data yang digunakan dalam penelitian ini adalah data Suhu Permukaan Tanah, karbon dioksida, dan karbon monoksida. Data tersebut dimodelkan menjadi data endogen dan eksogen. Data Suhu Permukaan Tanah merupakan data endogen, sedangkan data karbon dioksida dan karbon monoksida merupakan data eksogen. Penelitian ini menunjukkan hasil bahwa metode NNARX lebih baik dibandingkan metode SARIMAX jika dilihat dari karakteristik Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Hal tersebut diduga karena penentuan komponen AR dan MA pada model SARIMAX dilakukan secara manual dan tidak ada aturan yang jelas tentang bagaimana memutuskan komponen AR dan MA yang sesuai sehingga model yang digunakan kemungkinan mengandung bias karena menggunakan penilaian pribadi [53].

Berdasarkan hasil yang didapatkan, suhu permukaan bumi di Provinsi Kalimantan Timur diprediksi akan cenderung lebih tinggi pada tahun 2025. Hal tersebut secara tidak langsung mengonfirmasi kebenaran hipotesis mengenai terjadinya kenaikan suhu permukaan bumi di Provinsi Kalimantan Timur akibat dari pembangunan yang massif.

DAFTAR PUSTAKA

- [1] Houghton, J. (2005). Global warming. *Reports on Progress in Physics*, 68(6), 1343–1403. <https://doi.org/10.1088/0034-4885/68/6/R02>
- [2] Song, J., Tong, G., Chao, J., Chung, J., Zhang, M., Lin, W., Zhang, T., Bentler, P. M., & Zhu, W. (2023). Data driven pathway analysis and forecast of global warming and sea level rise. *Scientific Reports*, 13(1), 5536. <https://doi.org/10.1038/s41598-023-30789-4>
- [3] Smale, D. A., Wernberg, T., Oliver, E. C. J., Thomsen, M., Harvey, B. P., Straub, S. C., Burrows, M. T., Alexander, L. V., Benthuisen, J. A., Donat, M. G., Feng, M., Hobday, A. J., Holbrook, N. J., Perkins-Kirkpatrick, S. E., Scannell, H. A., Sen Gupta, A., Payne, B. L., & Moore, P. J. (2019). Marine heatwaves threaten global biodiversity and the provision of ecosystem services. *Nature Climate Change*, 9(4), 306–312. <https://doi.org/10.1038/s41558-019-0412-1>
- [4] Kartiasih, F., & Setiawan, A. (2020). Aplikasi Error Correction Mechanism Dalam Analisis Dampak Pertumbuhan Ekonomi, Konsumsi Energi dan Perdagangan Internasional Terhadap Emisi CO₂ di Indonesia. *Media Statistika*, 13(1), 104–115. <https://doi.org/10.14710/medstat.13.1.104-115>
- [5] Pribadi, W., & Kartiasih, F. (2020). Environmental Quality and Poverty Assessment in Indonesia. *Jurnal Pengelolaan Sumberdaya Alam Dan Lingkungan (Journal of Natural Resources and Environmental Management)*, 10(1), 89–97. <https://doi.org/10.29244/jpsl.10.1.89-97>
- [6] X. Liao, Y. Chen, H. Zhao, and X. Zhao, "Sensitivity Analysis of CO₂ Storage Coefficient and CO₂-EOR," in *2010 Asia-Pacific Power and Energy Engineering Conference*, 2010, pp. 1–6. doi: 10.1109/APPEEC.2010.5448135.
- [7] Conte, L., Szopa, S., Séférian, R., & Bopp, L. (2019). The oceanic cycle of carbon monoxide and its emissions to the atmosphere. *Biogeosciences*, 16(4), 881–902. <https://doi.org/10.5194/bg-16-881-2019>
- [8] Easterbrook, D. J. (2016). Greenhouse Gases. In *Evidence-Based Climate Science* (pp. 163–173). Elsevier. <https://doi.org/10.1016/B978-0-12-804588-6.00009-4>
- [9] Häder, D.-P., & Barnes, P. W. (2019). Comparing the impacts of climate change on the responses and linkages between terrestrial and aquatic ecosystems. *Science of The Total Environment*, 682, 239–246. <https://doi.org/10.1016/j.scitotenv.2019.05.024>
- [10] Frame, D. J., Rosier, S. M., Noy, I., Harrington, L. J., Carey-Smith, T., Sparrow, S. N., Stone, D. A., & Dean, S. M. (2020). Climate change attribution and the economic costs of extreme weather events: a study on damages from extreme rainfall and drought. *Climatic Change*, 162(2), 781–797. <https://doi.org/10.1007/s10584-020-02729-y>
- [11] Shukla, J. B., Arora, M. S., Verma, M., Misra, A. K., & Takeuchi, Y. (2021). The Impact of Sea Level Rise Due to Global Warming on the Coastal Population Dynamics: A Modeling Study. *Earth Systems and Environment*, 5(4), 909–926. <https://doi.org/10.1007/s41748-021-00246-1>
- [12] Mikhaylov, A., Moiseev, N., Aleshin, K., & Burkhardt, T. (2020). Global climate change and greenhouse effect. *Entrepreneurship and Sustainability Issues*, 7(4), 2897–2913. [https://doi.org/10.9770/jesi.2020.7.4\(21\)](https://doi.org/10.9770/jesi.2020.7.4(21))
- [13] Wossen, T., Berger, T., Haile, M. G., & Troost, C. (2018). Impacts of climate variability and food price volatility on household income and food security of farm households in East and West Africa. *Agricultural Systems*, 163, 7–15. <https://doi.org/10.1016/j.agsy.2017.02.006>
- [14] Scher, S., & Messori, G. (2019). How Global Warming Changes the Difficulty of Synoptic Weather Forecasting. *Geophysical Research Letters*, 46(5), 2931–2939. <https://doi.org/10.1029/2018GL081856>
- [15] Laras Tursilowati, Rachmat Sunarya, Muzirwan, Edy Maryadi, Indah Susanti, Soni Aulia Rahayu, Tatik Kartika, Mamat Suhermat, Jamrud Aminuddin, & Nursida Arif. (2023). Observasi Pulau Panas Perkotaan Musim Menggunakan Remote Sensing dan Google Earth Engine Di Ibukota Baru Indonesia. *Jurnal Universitas Jiaotong Barat Daya*, 58(4). <https://doi.org/10.35741/issn.0258-2724.58.4.88>
- [16] A. Cheshmehzangi, "The Analysis of Global Warming Patterns from 1970s to 2010s," *Atmos. Clim. Sci.*, vol. 10, no. 03, pp. 392–404, 2020, doi: 10.4236/acs.2020.103022.
- [17] Salwan, A. A., Ahmed, A. A., & Salim, M. A. (2021). Using ArcGIS Software and Remote Sensing Technology to Predict Land Surface Temperature (LST) for Monitoring Ecological and Climate Change in Hor Al-Dalmaj, Southern Iraq. *IOP Conference Series: Earth and Environmental Science*, 790(1). <https://doi.org/10.1088/1755-1315/790/1/012076>
- [18] Abdullah-Al-Faisal, Abdulla - Al Kafy, Foyezur Rahman, A. N. M., Rakib, A. Al, Akter, K. S., Raikwar, V., Jahir, D. M. A., Ferdousi, J., & Kona, M. A. (2021). Assessment and prediction of seasonal land surface temperature change using multi-temporal Landsat images and their impacts on agricultural yields in Rajshahi, Bangladesh. *Environmental Challenges*, 4. <https://doi.org/10.1016/j.envc.2021.100147>
- [19] Mustafa, E. K., Co, Y., Liu, G., Kaloom, M. R., Beshr, A. A., Zarzoura, F., & Sadek, M. (2020). Study for Predicting Land Surface Temperature (LST) Using Landsat Data: A Comparison of Four Algorithms. *Advances in Civil Engineering*, 2020. <https://doi.org/10.1155/2020/7363546>
- [20] Malakouti, S. M. (2023). Utilizing time series data from 1961 to 2019 recorded around the world and machine learning to create a Global Temperature Change Prediction Model. *Case Studies in Chemical and Environmental Engineering*, 7. <https://doi.org/10.1016/j.csee.2023.100312>
- [21] Alharbi, F. R., & Csala, D. (2022). A Seasonal Autoregressive Integrated Moving Average with Exogenous Factors (SARIMAX) Forecasting Model-Based Time Series Approach. *Inventions*, 7(4), 94. <https://doi.org/10.3390/inventions7040094>
- [22] Ruslan, F. A., Samad, A. M., Tajjudin, M., & Adnan, R. (2016). 7 hours flood prediction modelling using NNARX structure: Case study Terengganu. *2016 IEEE 12th International Colloquium on*

- Signal Processing & Its Applications (CSPA)*, 263–268. <https://doi.org/10.1109/CSPA.2016.7515843>
- [23] Li, Z. L., Wu, H., Duan, S. B., Zhao, W., Ren, H., Liu, X., Leng, P., Tang, R., Ye, X., Zhu, J., Sun, Y., Si, M., Liu, M., Li, J., Zhang, X., Shang, G., Tang, B. H., Yan, G., & Zhou, C. (2023). Satellite Remote Sensing of Global Land Surface Temperature: Definition, Methods, Products, and Applications. In *Reviews of Geophysics* (Vol. 61, Issue 1). John Wiley and Sons Inc. <https://doi.org/10.1029/2022RG000777>
- [24] Guillevic, P., Götsche, F., Nickeson, J., Hulley, G., Ghent, D., Yu, Y., Trigo, I., Hook, S., Sobrino, J.A., Remedios, J., Román, M. & Camacho, F. (2018). Land Surface Temperature Product Validation Best Practice Protocol. Version 1.1. In P. Guillevic, F. Götsche, J. Nickeson & M. Román (Eds.), *Good Practices for Satellite-Derived Land Product Validation* (p. 58): Land Product Validation Subgroup (WGCV/CEOS), doi:10.5067/doc/ceoswgc/1pv/1st.001
- [25] Hollmann, R., Merchant, C. J., Saunders, R., Downy, C., Buchwitz, M., Cazenave, A., Chuvieco, E., Defourny, P., de Leeuw, G., Forsberg, R., Holzer-Popp, T., Paul, F., Sandven, S., Sathyendranath, S., van Roozendaal, M., & Wagner, W. (2013). The ESA Climate Change Initiative: Satellite Data Records for Essential Climate Variables. *Bulletin of the American Meteorological Society*, 94(10), 1541–1552. <https://doi.org/10.1175/BAMS-D-11-00254.1>
- [26] Li, Z.-L., Tang, B.-H., Wu, H., Ren, H., Yan, G., Wan, Z., Trigo, I. F., & Sobrino, J. A. (2013). Satellite-derived land surface temperature: Current status and perspectives. *Remote Sensing of Environment*, 131, 14–37. <https://doi.org/10.1016/j.rse.2012.12.008>
- [27] Heizer, J., & Render, B. (2015). *Operations Management: Sustainability and Supply Chain Management* (Ed. 11). New Jersey: Pearson Education Inc.
- [28] Chambers, J. Q., Fisher, J. I., Zeng, H., Chapman, E. L., Baker, D. B., & Hurr, G. C. (2007). Hurricane Katrina's Carbon Footprint on U.S. Gulf Coast Forests. *Science*, 318(5853), 1107–1107. <https://doi.org/10.1126/science.1148913>
- [29] Kenny, T., & Gray, N. F. (2009). Comparative performance of six carbon footprint models for use in Ireland. *Environmental Impact Assessment Review*, 29(1), 1–6. <https://doi.org/10.1016/j.eiar.2008.06.001>
- [30] Nurulita, "Penerapan Metode Peramalan ARIMA untuk Penentuan Tingkat Safety Stock pada Industri Elektronik," Skripsi, Universitas Indonesia, Fakultas Teknik, Program Studi Teknik Industri, Depok, Juli 2010.
- [31] H. Patel, "What are ARIMA and SARIMA Models?", *Becoming Human: Artificial Intelligence Magazine*. Tersedia: <https://becominghuman.ai/what-is-arima-and-sarima-model-10972b5e13c0>. Diakses pada: November 2023.
- [32] B. Artley, "Time Series Forecasting with ARIMA, SARIMA and SARIMAX: A deep-dive on the gold standard of time series forecasting," *Toward Data Science*. Tersedia: <https://towardsdatascience.com/time-series-forecasting-with-arima-sarima-and-sarimax-ee61099e78f6>. Diakses pada: November 2023.
- [33] Arunraj, N. S., Ahrens, D., & Fernandes, M. (2016). Application of SARIMAX Model to Forecast Daily Sales in Food Retail Industry. *International Journal of Operations Research and Information Systems*, 7(2), 1–21. <https://doi.org/10.4018/IJORIS.2016040101>
- [34] Cox, D. D., & Dean, T. (2014). Neural Networks and Neuroscience-Inspired Computer Vision. *Current Biology*, 24(18), R921–R929. <https://doi.org/10.1016/j.cub.2014.08.026>
- [35] Boussaada, Z., Curea, O., Remaci, A., Camblong, H., & Mrabet Bellaaj, N. (2018). A Nonlinear Autoregressive Exogenous (NARX) Neural Network Model for the Prediction of the Daily Direct Solar Radiation. *Energies*, 11(3), 620. <https://doi.org/10.3390/en11030620>
- [36] Araújo, R. de A., Oliveira, A. L. I., & Meira, S. (2017). A morphological neural network for binary classification problems. *Engineering Applications of Artificial Intelligence*, 65, 12–28. <https://doi.org/10.1016/j.engappai.2017.07.014>
- [37] Gong, T., Fan, T., Guo, J., & Cai, Z. (2017). GPU-based parallel optimization of immune convolutional neural network and embedded system. *Engineering Applications of Artificial Intelligence*, 62, 384–395. <https://doi.org/10.1016/j.engappai.2016.08.019>
- [38] Sánchez, D., Melin, P., & Castillo, O. (2017). Optimization of modular granular neural networks using a firefly algorithm for human recognition. *Engineering Applications of Artificial Intelligence*, 64, 172–186. <https://doi.org/10.1016/j.engappai.2017.06.007>
- [39] M. R. Sultan Mohd, J. Johari, and F. A. Ruslan, "Application of NNARX in Modeling a Solar Radiation Prediction," in *2020 IEEE 8th Conference on Systems, Process and Control (ICSPC)*, Dec. 2020, pp. 225–229. doi: 10.1109/ICSPC50992.2020.9305787.
- [40] Ruslan, F. A., Samad, A. M., & Adnan, R. (2017). Modelling of flood prediction system using hybrid NNARX and Extended Kalman Filter. *2017 IEEE 13th International Colloquium on Signal Processing & Its Applications (CSPA)*, 149–152. <https://doi.org/10.1109/CSPA.2017.8064941>
- [41] Coronado-Martinez, F. U., Ruiz-Sanchez, F. J., & Suarez-Cerda, D. A. (2017). Fault detection and diagnosis of complex engineering systems based on a NNARX multi model applied to a fossil fuel electric power plant. *2017 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, 1–6. <https://doi.org/10.1109/ROPEC.2017.8261601>
- [42] Protic, D., & Milosavljevic, M. (n.d.). NNARX Model of Speech Signal Generating System: Test Error Subject to Modeling Mode Selection. *2006 25th International Conference on Microelectronics*, 643–646. <https://doi.org/10.1109/ICMEL.2006.1651050>
- [43] Shafer Al-Gounmmeen, R., & Tahir Ismail, M. (2020). Forecasting the Exchange Rate of the Jordanian Dinar versus the US Dollar Using a Box-Jenkins Seasonal ARIMA Model. *International Journal of Mathematics and Computer Science*, 15(1), 27–40. <http://ijmcs.future-in-tech.net>
- [44] C. Tze-Haw, L. C. Teck, and H. Chee-Wooi, "Forecasting Malaysian ringgit: Before and after the global crisis," *Asian Acad. Manag. J. Account. Financ.*, vol. 9, no. 2, pp. 157–175, 2013
- [45] Badan Meteorologi, Klimatologi, dan Geofisika. (2023, September). *Informasi Parameter Iklim [Anomali suhu udara rata-rata bulanan]*. <https://www.bmkg.go.id/iklim/?p=ekstrem-perubahan-iklim>
- [46] DC Montgomery, CL Jennings, M. Kulahci, *Introduction to Time Series Analysis and Forecasting*, Edisi ke-2, Wiley & Sons Inc., 2015, 643.
- [47] S. Pählman, "The effect of rising interest rates on Swedish condominium prices Emil Bengtson," 2020.
- [48] P. Manigandan et al., "Forecasting Natural Gas Production and Consumption in United States-Evidence from SARIMA and SARIMAX Models," *Energies*, vol. 14, no. 19, p. 6021, Sep. 2021, doi: 10.3390/en14196021.
- [49] F. R. Alharbi and D. Csala, "Wind Speed and Solar Irradiance Prediction Using a Bidirectional Long Short-Term Memory Model Based on Neural Networks," *Energies*, vol. 14, no. 20, p. 6501, Oct. 2021, doi: 10.3390/en14206501.
- [50] S. I. Vagropoulos, G. I. Chouliaras, E. G. Kardakos, C. K. Simoglou, and A. G. Bakirtzis, "Comparison of SARIMAX, SARIMA, modified SARIMA and ANN-based models for short-term PV generation forecasting," in *2016 IEEE International Energy Conference (ENERGYCON)*, Apr. 2016, pp. 1–6. doi: 10.1109/ENERGYCON.2016.7514029.
- [51] A. Tarsitano and I. L. Amerise, "Short-term load forecasting using a two-stage sarimax model," *Energy*, vol. 133, pp. 108–114, Aug. 2017, doi: 10.1016/j.energy.2017.05.126.
- [52] S. Udi, P. & Etuk, and E. Harrison, "Comparative Performance of Garch and Sarima Techniques in the Modeling of Nigerian Broad Money," *CARD Int. J. Soc. Sci. Confl. Manag.*, vol. 2, no. 4, pp. 2536–7242, 2017, [Online]. Available: <http://www.casirmediapublishing.com>
- [53] T. Nyoni, "Box-Jenkins ARIMA approach to predicting net FDI inflows in Zimbabwe," *9th Eur. Conf. Mach. Learn. Poster Pap.*, no. 87737, pp. 128–137, 2018, [Online]. Available: <https://ideas.repec.org/p/pramprapa/87737.html>
- [54] M. R. S. Mohd, J. Johari, and F. A. Ruslan, "Application of NNARX in Modeling a Solar Radiation Prediction," *Proceeding - 2020 IEEE 8th Conf. Syst. Process Control. ICSPC 2020*, no. December, pp. 225–229, 2020, doi: 10.1109/ICSPC50992.2020.9305787.

- [55] H. Larochelle, Y. Bengio, J. Louradour, and P. Lamblin, "Exploring strategies for training deep neural networks," *J. Mach. Learn. Res.*, vol. 10, pp. 1–40, 2009.
- [56] Lv, C.-X., An, S.-Y., Qiao, B.-J., & Wu, W. (2021). Time series analysis of hemorrhagic fever with renal syndrome in mainland China by using an XGBoost forecasting model. *BMC Infectious Diseases*, 21(1), 839. <https://doi.org/10.1186/s12879-021-06503-y>