



Prediksi Harian Suhu Udara Permukaan dengan Jaringan Syaraf Tiruan : Studi Kasus di Kawasan perkotaan dan Pesisir Jakarta, Indonesia

Daily Surface Temperature Prediction using Artificial Neural Network : A Case study at Urban Area and Coastal Area of Jakarta, Indonesia

Richard Mahendra Putra*, Eka Fibriantika, Yetti Kusumayanti, Erlya Afriani, Arifatul Hidayanti, Wishnu Agum Swastiko, Helminah Herawati, Atri Wiujiana

Badan Meteorologi Klimatologi dan Geofisika, Jakarta Pusat, DKI Jakarta, 10610

*Email: richardmahendrap@gmail.com

Naskah Masuk: 25 Januari 2023 / Naskah Diterima: 28 Mei 2023 / Naskah Terbit: 10 Juni 2023

Abstrak. Prakiraan cuaca sangat penting untuk melindungi kehidupan dan harta benda. Prakiraan suhu penting untuk sektor pertanian dikarenakan ketika suhu udara yang tinggi dapat menyebabkan tanah lebih cepat mengering dan mengurangi ketersediaan air bagi tanaman. Selain itu, memahami kondisi suhu dapat membantu ahli meteorologi untuk memprakirakan kondisi atmosfer lainnya. Tujuan dari penelitian ini adalah membuat pemodelan prediksi kondisi suhu udara pada hari berikutnya dengan menggunakan model jaringan syaraf tiruan (JST). Untuk membuat model JST, suhu rata – rata harian yang diukur pada stasiun meteorologi di wilayah perkotaan dan pesisir Jakarta selama 2010 – 2019 yang digunakan sebagai data pelatihan. Data pengujian menggunakan suhu permukaan selama Januari – Desember 2020. Model ini menggunakan berbagai jumlah neuron pada lapisan tersembunyi antara 3 dan 15. Berdasarkan hasil, model JST cukup baik untuk memprediksi kondisi suhu di Jakarta dengan korelasi antara 0.625 – 0.653 dan *mean absolute error* (MAE) antara 0.569 – 0.600 °C. Model prediksi terbaik didapatkan pada jumlah neuron 4 di Area Perkotaan Jakarta dan neuron 8 di Area Pesisir Jakarta, dilihat dari nilai korelasi yang tinggi dengan observasi dan tingkat kesalahan yang rendah.

Kata Kunci: Suhu Udara, Jaringan Syaraf tiruan, Jakarta

Abstract. The weather forecast is significant to protect life and property. A forecast of temperature is important to the agriculture sector because when high temperatures can cause the soil to dry out faster and reduce the availability of water for plants. Furthermore, understanding the temperature condition can help meteorologists forecast the other atmosphere condition. The purpose of this research is to make a modeling prediction of temperature conditions the next day using an artificial neural network model (ANN). To make the ANN model, the daily average temperature measured in the meteorological stations in the urban and the coastal areas of Jakarta over 2010 – 2019 was used as training data. The testing data using surface temperature during January – December 2020. This model uses the various number of neurons in the hidden lapisan between 3 and 15. Based on the result, the ANN model is good enough to predict the temperature condition in Jakarta with the correlation between 0.625 – 0.653 and mean absolute error (MAE) between 0.569 – 0.600 °C. The best model prediction was obtained when the neuron number was 4 in the Urban Area of

Jakarta and 8 in the Coastal Area of Jakarta seen from the high correlation value with the observations and a low error rate.

Keywords: Temperature, Artificial Neural Network, Jakarta

Pendahulun

Gambaran kondisi terestrial bumi ditunjukkan oleh suhu udara^[1]. Suhu udara merupakan salah satu faktor yang menentukan perkembangan dan pertumbuhan tumbuhan, kebutuhan hewan akan makanan, dan awal siklus reproduksi baik tumbuhan maupun hewan^[2]. Suhu udara juga sangat menentukan kenyamanan manusia, terutama di ruang terbuka publik^{[3], [4]}. Prediksi suhu yang akurat tidak hanya penting bagi komponen biotik tetapi juga berperan penting dalam kegiatan perencanaan bagi pemerintah, industri, dan masyarakat^[5].

Pemanasan udara dan lautan adalah tanda paling awal dari perubahan iklim^[6]. Daerah sabuk tropis yang dicirikan oleh suhu hangat dengan perubahan musiman dan harian yang kecil dibandingkan dengan iklim ekstratropis merupakan daerah penting dalam sistem iklim global. Selama beberapa dekade terakhir, beberapa penelitian menunjukkan bahwa sabuk tropis telah meluas yang dapat menyebabkan perubahan besar dalam sistem iklim global^[6]. Penelitian sebelumnya menemukan tren pemanasan yang signifikan secara spasial dalam indeks suhu di Indonesia selama tiga dekade terakhir (1983 – 2012)^[7]. Oleh karena itu, prediksi suhu udara di daerah tropis sangat penting.

Machine Learning didefinisikan sebagai cabang dari bidang Kecerdasan Buatan. Tujuan utama dari algoritma yang dikembangkan pada area ini adalah untuk mendapatkan model matematis yang sesuai dengan data^[5]. Pembelajaran mesin adalah model yang belajar dari data atau pengalaman. Dalam pembuatan model prediksi dibutuhkan hingga beberapa parameter, dan pembelajaran adalah pelaksanaan program komputer untuk mengoptimalkan parameter model menggunakan data pelatihan atau pengalaman^[8]. Model dapat bersifat prediktif untuk membuat prediksi di masa depan, atau deskriptif untuk mendapatkan pengetahuan dari data, atau keduanya^[9].

Penggunaan utama pembelajaran mesin adalah untuk mengajari mesin cara menangani data dengan lebih efisien. Pembelajaran mesin diatur untuk belajar dari data dan menemukan solusinya^[10]. Konsep *machine learning* telah digunakan dalam penelitian yang berkaitan dengan ilmu atmosfer, khususnya dalam prediksi cuaca. Beberapa penelitian yang menggunakan *machine learning* untuk memprediksi kondisi cuaca harian^[11], pola suhu^[12], prediksi bulanan suhu udara^[13], prediksi suhu udara menggunakan pendekatan memori jangka pendek^[14], prediksi suhu udara harian^[15], dan pemodelan angin ketika siklon tropis^[16]. Pembelajaran mesin juga diterapkan dalam studi polusi perkotaan, seperti pemodelan polusi perkotaan^[17] dan memperkirakan konsentrasi partikel^[18].

Di daerah perkotaan, suhu udara sangat penting dalam menilai *Urban Heat Island* (UHI), fenomena yang paling banyak didokumentasikan dalam klimatologi perkotaan^[18]. Daerah perkotaan memiliki karakteristik suhu permukaan yang lebih hangat daripada di daerah pedesaan^[19]. Menurut Geiger dkk (1995)^[20], albedo permukaan merupakan variabel paling kritis yang menentukan perubahan siang dan malam suhu udara luar ruangan di daerah perkotaan. Iklim pesisir adalah salah satu contoh dari iklim transisi tersebut^[19]. Parsel udara dingin yang lembab dari atas air mengalir di atas udara yang lebih panas di dekat permukaan tanah pada siang hari, tetapi pada malam hari, udara dingin turun ke arah perairan. Penelitian sebelumnya^[21] berpendapat bahwa suhu udara merupakan faktor geometri jalan yang paling krusial dalam studi iklim mikro perkotaan di kota – kota pantai tropis. Oleh karena itu, tim penulis tertarik untuk memprediksi suhu udara sebagai faktor yang signifikan dalam iklim mikro perkotaan di perkotaan (Stasiun Meteorologi Kemayoran) dan wilayah pesisir (Stasiun Meteorologi Tanjung Priok). Tujuan penelitian ini adalah membuat pemodelan prakiraan suhu permukaan harian

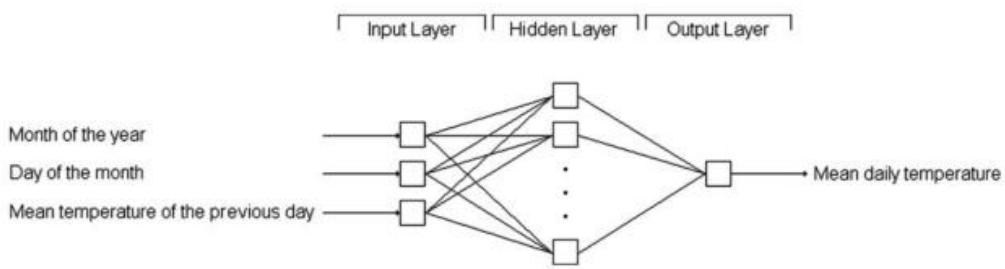
menggunakan Jaringan Syaraf Tiruan (JST) di wilayah perkotaan dan pesisir Jakarta. Model ini dilatih dari 2010 – 2019 dan diuji pada 2020.

Metode Penelitian

Pemodelan lingkungan melibatkan penggunaan berbagai pendekatan tergantung pada kompleksitas masalah. Aplikasi dalam ilmu atmosfer telah menggunakan pendekatan JST [22]. Menurut beberapa referensi, JST telah diterapkan pada variabel cuaca yang dihasilkan dalam model NWP, khususnya dalam keterampilan prakiraan cuaca [23]. Pemodelan JST dibangun untuk menunjukkan hubungan antara lapisan input dan output yang mengacu pada desain jaringan [24]. Dalam memastikan konvergensi skema, nilai input harus sesuai dengan nilai output berdasarkan pasangan pelatihan. Kita dapat berasumsi bahwa setiap lapisan membawa data yang membuat koneksi ke nilai tersebut. Lapisan memiliki neuron di mana bias, bobot, dan fungsi transfer dikecualikan.

Data historis dari suhu rata – rata harian dari Stasiun Meteorologi Kemayoran dan Stasiun Meteorologi Tanjung Priok digunakan dalam penelitian ini. Lokasi – lokasi tersebut secara berurutan mewakili wilayah perkotaan dan pesisir di Jakarta. Stasiun ini terletak di wilayah Jakarta di 6.18 LS 106.833 BT (Kemayoran) dan 6.1 LS 106.8 BT (Tanjung Priok) dengan ketinggian masing – masing 4 dan 3 m di atas permukaan laut. Data rentang periode 2010 hingga 2019 digunakan sebagai data latih dan data suhu permukaan periode Januari hingga Desember 2020 sebagai data uji.

Model jaringan syaraf tiruan ini terdiri dari 3 lapisan, yaitu lapisan masukan, lapisan tersembunyi, dan lapisan output. Lapisan input merupakan lapisan pertama pada jaringan syaraf tiruan yang menerima data masukan dari luar. Data masukan ini kemudian diproses oleh jaringan syaraf untuk menghasilkan output yang diinginkan. Setiap neuron pada lapisan input mewakili sebuah fitur dari data masukan. Lapisan tersembunyi adalah lapisan yang terletak di antara lapisan input dan lapisan output. Lapisan ini bertanggung jawab untuk memproses informasi yang diterima dari lapisan input dan mentransfer informasi tersebut ke lapisan output. Lapisan tersembunyi terdiri dari beberapa neuron, yang masing – masing memproses informasi dari neuron sebelumnya untuk menghasilkan output yang lebih kompleks. Lapisan output merupakan lapisan terakhir pada jaringan syaraf tiruan yang menghasilkan output akhir. Setiap neuron pada lapisan output mewakili kelas atau nilai yang ingin diprediksi oleh jaringan syaraf. Output dari lapisan ini merupakan hasil akhir dari proses pemrosesan informasi yang dilakukan oleh jaringan syaraf. Selama proses pelatihan, dilakukan variasi jumlah neuron di lapisan tersembunyi antara 3 dan 15. Nilai input dibangun sebagai produk, yang menjumlahkan input dengan bobot. Proses pelatihan mengaitkan satu input koresponden dengan satu output. Pada penelitian ini, model jaringan syaraf tiruan menggunakan tiga macam input, yaitu bulan dalam tahun, hari dalam bulan, dan nilai suhu rata – rata pada hari sebelumnya [25] sesuai referensi penelitian sebelumnya. Keluaran dari model ini berupa prediksi suhu keesokan harinya yang ditentukan oleh masukan.



Gambar 1. Arsitektur desain model [23]

Hasil keluaran suhu permukaan harian dari model dibandingkan dengan data pengamatan suhu permukaan harian. Analisis tingkat kesalahan model dilakukan dengan menggunakan indeks *Mean*

Absolute Error (MAE). MAE memberikan hasil yang dapat diinterpretasikan secara langsung. Hasil MAE akan memberikan informasi tentang seberapa besar kesalahan prediksi dalam satuan yang sama dengan data yang diprediksi. Hal ini memudahkan pengguna untuk memahami seberapa akurat model prediksi yang dibuat. Semakin besar nilai MAE maka semakin besar tingkat kesalahan dari output yang menunjukkan bahwa model tidak optimal dalam membuat peramalan suhu. Secara matematis, nilai MAE dapat dihitung sebagai berikut [26]:

$$MAE = \frac{\sum_{i=1}^n |TM_i - TO_i|}{n} \quad (1)$$

MAE = Berarti Kesalahan Mutlak
 TM = Keluaran Pemodelan Jaringan Syaraf Tiruan
 TO = Pengamatan Suhu Udara
 n = Banyaknya data
 i = data ke – I

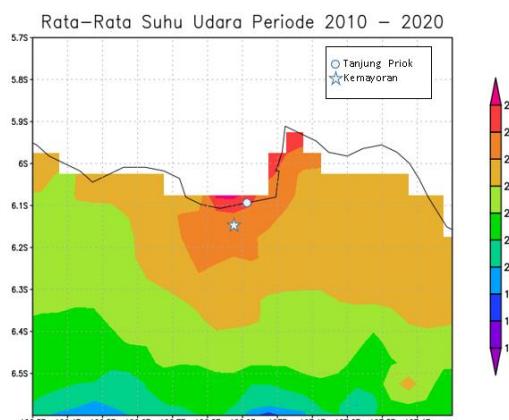
Selain itu, hasil performa model juga dapat dilihat dari hubungan antar output model dan hasil pengamatan sebenarnya berdasarkan nilai korelasinya. Nilai Korelasi sering digunakan dalam analisis statistik untuk menentukan keterkaitan antara variable – variabel yang diamati. Dalam analisis multivariat, korelasi digunakan untuk menentukan korelasi antara beberapa variabel yang saling terkait. Tingkat Korelasi sebuah output model dan hasil observasinya dapat dihitung menggunakan rumus berikut [26]:

$$R = \frac{\sum_{i=1}^n (TO_i - \bar{TO})(TM_i - \bar{TM})}{\sqrt{\sum_{i=1}^n (TO_i - \bar{TO})^2} \sqrt{\sum_{i=1}^n (TM_i - \bar{TM})^2}} \quad (2)$$

Keterangan :

R = Indeks Korelasi
 TM = Prediksi Model Suhu Udara
 \bar{TM} = Rata – Rata Prediksi Model Suhu Udara
 TO = Suhu Udara Pengamatan
 \bar{TO} = Rata – rata Suhu Udara Pengamatan
 n = jumlah data

Hasil dan Pembahasan



Gambar 2. Distribusi Spasial Suhu Udara Rata – rata periode 2010 – 2020 berdasarkan data MODIS – Aqua MYD11C3 v006

Pola sebaran suhu udara yang terjadi di wilayah Jakarta dan sekitarnya memiliki karakteristik yang berbeda di setiap area. Untuk wilayah di perkotaan memiliki suhu yang lebih tinggi dibandingkan di wilayah yang memiliki topografi tinggi seperti di selatan Jakarta. Sedangkan untuk area Tanjung Priok memiliki suhu yang lebih tinggi dibandingkan wilayah lainnya. Hal ini kemungkinan disebabkan oleh wilayah Tanjung Priok memiliki pelabuhan laut dan aktivitas industri yang cukup padat, sehingga bangunan – bangunan yang terdapat di sekitar Tanjung Priok banyak yang terbuat dari bahan – bahan seperti beton dan aspal yang dapat menyerap panas dari sinar matahari dan melepaskannya ke lingkungan sekitarnya.

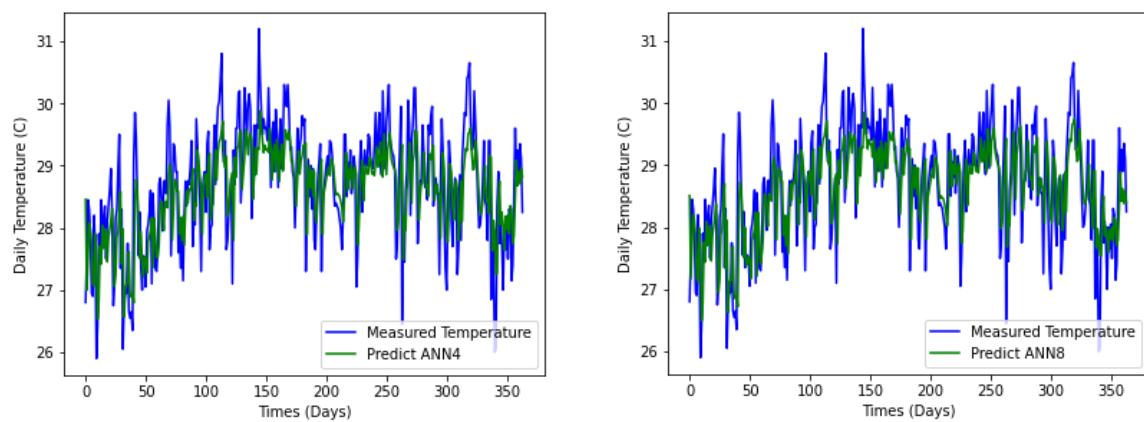
Pada penelitian ini, variabel suhu udara diamati dari Stasiun Meteorologi Kemayoran sebagai Kawasan Perkotaan dan Stasiun Meteorologi Tanjung Priok sebagai Wilayah Pesisir. Model prediksi suhu permukaan harian dilatih dengan menggunakan data suhu tahun 2010 – 2019 dan diuji pada tahun 2020. Perhitungan Korelasi (R) dan *Mean Absolute Error* (MAE) sebagai output forecast ditunjukkan pada Tabel 1.

Pembahasan berikut adalah tentang kinerja output model. Berdasarkan hasil, nilai korelasi model dibandingkan dengan data yang diamati menunjukkan nilai 0.636 hingga 0.653 di daerah perkotaan. Sementara itu, menunjukkan nilai antara 0.625 hingga 0.650 di wilayah pesisir. Selanjutnya, nilai MAE antara 0.574 sampai 0.588 di daerah perkotaan dan 0.569 sampai 0.600 di daerah pesisir. Pada penelitian sebelumnya ^[27] memprediksi suhu harian, tetapi dalam kasus suhu permukaan laut menunjukkan hasil yang baik. *Mean Absolute Error* (MAE) antara 0.28 – 0.49 menggunakan Teknik Syaraf Tiruan dan penelitian lain ^[28] menyebutkan nilai error antara 0.18 hingga 0.32 °C untuk ramalan 5 hari ke depan menggunakan jaringan saraf efisien.

Tabel 1. Korelasi dan Mean Absolute Error Model JST

Jumlah Neuron	Daerah Perkotaan		Wilayah Pesisir	
	Korelasi (R)	Rata-Rata Kesalahan Mutlak (MAE)	Korelasi (R)	Rata-Rata Kesalahan Mutlak (MAE)
3	0.645	0.579	0.648	0.577
4	0.653	0.574	0.646	0.578
5	0.644	0.578	0.640	0.582
6	0.652	0.578	0.643	0.577
7	0.647	0.588	0.641	0.593
8	0.653	0.579	0.649	0.569
9	0.650	0.581	0.637	0.585
10	0.645	0.583	0.640	0.580
11	0.645	0.580	0.650	0.580
12	0.652	0.587	0.647	0.582
13	0.639	0.587	0.625	0.600
14	0.644	0.588	0.641	0.589
15	0.636	0.583	0.646	0.579

Berdasarkan hasil tersebut, model jaringan syaraf tiruan paling representatif untuk daerah perkotaan adalah model dengan 4 neuron pada lapisan tersembunyi. Sedangkan untuk wilayah pesisir. model yang paling representatif adalah 8 neuron pada lapisan tersembunyi. Ini adalah ditunjukkan oleh MAE yang rendah dan korelasi yang tinggi dibandingkan output lainnya.



Gambar 3. Perbandingan Model Jaringan Syaraf Tiruan dan Data Pengamatan di (a) Wilayah Perkotaan dan (b) Wilayah Pesisir Jakarta

Model jaringan syaraf tiruan yang paling representatif diplot berdasarkan deret waktu selama tahun 2020 seperti yang ditunjukkan oleh Gambar 3. Berdasarkan hasil, dapat diasumsikan bahwa suhu permukaan harian yang diprediksi memiliki pola yang sama untuk kedua area saat suhu naik dan turun. Keluaran prediksi dari model sangat dekat dengan data observasi untuk data pengujian tahun 2020. Berdasarkan hasil tersebut, dapat disimpulkan bahwa modeling suhu udara dengan algoritma ini dapat diimplementasikan di wilayah Jakarta.

Kesimpulan

Dalam kajian ini, telah ditemukan bahwa jaringan saraf tiruan cukup baik untuk memprediksi kondisi suhu pada hari selanjutnya dengan menggunakan input data bulan, harian, dan nilai suhu hari sebelumnya. Korelasi model output adalah 0.653, disertai error 0.574 di wilayah perkotaan Jakarta. Sedangkan wilayah pesisir Jakarta menunjukkan nilai korelasi terbaik sebesar 0.650 dan error sebesar 0.569. Hasil terbaik dari keluaran model diperoleh dari Jaringan Syaraf Buatan yang terdiri dari 4 neuron pada lapisan tersembunyi dan 8 neuron pada lapisan tersembunyi masing – masing untuk wilayah perkotaan dan pesisir. Selain itu, output model terbaik dapat terlihat dari tingkat korelasi yang tinggi disertai nilai kesalahan yang rendah. Sehingga dapat disimpulkan bahwa model dengan arsitektur jaringan syaraf tiruan seperti ini adalah yang terbaik untuk kasus pada penelitian ini.

Daftar Pustaka

- [1] L. Prihodko and S. N. Goward. “Estimation of air temperature from remotely sensed surface observations.” *Remote Sens. Environ.*, vol. 60, no. 3, pp. 335–346, 1997.
- [2] J. Monteith and M. Unsworth. *Principles of environmental physics: plants, animals, and the atmosphere*. Academic Press, 2013.
- [3] H. Andrade, M.-J. Alcoforado, and S. Oliveira. “Perception of temperature and wind by users of public outdoor spaces: relationships with weather parameters and personal characteristics.” *Int. J. Biometeorol.*, vol. 55, pp. 665–680, 2011.
- [4] K. Isnoor, A. B. Putra, and M. A. Firmantari. “Analisis Kenyamanan Termal Berdasarkan Temperature Humidity Index dan Pengaruhnya Terhadap Curah Hujan di Kota Tanjungpinang.” *Bul. GAW Bariri*, vol. 2, no. 1, pp. 1–6, 2021.
- [5] J. Cifuentes, G. Marulanda, A. Bello, and J. Reneses. “Air temperature forecasting using machine learning techniques: a review.” *Energies*, vol. 13, no. 16, p. 4215, 2020.
- [6] D. J. Seidel, Q. Fu, W. J. Randel, and T. J. Reichler. “Widening of the tropical belt in a changing climate.” *Nat. Geosci.*, vol. 1, no. 1, pp. 21–24, 2008.
- [7] E. Supari, Tangang, F. Juneng, L. and Aldrian. “Observed changes in extreme temperature and precipitation over Indonesia.” *Int. J. Climatol.*, vol. 37, no. 4, pp. 1979–1997, 2017. doi:

- https://doi.org/10.1002/joc.4829.
- [8] M. Ryan and S. Alfiandy. "Prediksi Kecepatan Angin 12 Jam Kedepan Menggunakan Automatic Weather Observing System (AWOS) Berbasis Regresi Linear." *Bul. GAW Bariri*. vol. 3. no. 2. pp. 1–7. 2022.
- [9] Y. Baştanlar and M. Özysal. "Introduction to machine learning." *miRNomics MicroRNA Biol. Comput. Anal.*. pp. 105–128. 2014.
- [10] B. Mahesh. "Machine learning algorithms—a review." *Int. J. Sci. Res. (IJSR). [Internet]*. vol. 9. pp. 381–386. 2020.
- [11] R. M. Putra and N. A. Rani. "Prediksi Curah Hujan Harian di Stasiun Meteorologi Kemayoran Menggunakan Artificial Neural Network (ANN)." *Bul. GAW Bariri*. vol. 1. no. 2. pp. 101–108. 2020.
- [12] H. Tyagi. S. Suran. and V. Pattanaik. "Weather–temperature pattern prediction and anomaly identification using artificial neural network." *Int. J. Comput. Appl.*. vol. 975. p. 8887. 2016.
- [13] S. Salcedo-Sanz. R. C. Deo. L. Carro-Calvo. and B. Saavedra-Moreno. "Monthly prediction of air temperature in Australia and New Zealand with machine learning algorithms." *Theor. Appl. Climatol.*. vol. 125. pp. 13–25. 2016.
- [14] P. H. Gunawan. D. Munandar. and A. Z. Farabiba. "Long Short-Term Memory Approach for Predicting Air Temperature In Indonesia." *J. Online Inform.*. vol. 5. no. 2. pp. 161–168. 2020.
- [15] N. X. Trinh. T. Q. Trinh. T. P. Phan. T. N. Thanh. and B. N. Thanh. "Water temperature prediction models in northern coastal area. Vietnam." *Asian Rev. Environ. Earth Sci.*. vol. 6. no. 1. pp. 1–8. 2019.
- [16] T. Loridan. R. P. Crompton. and E. Dubossarsky. "A machine learning approach to modeling tropical cyclone wind field uncertainty." *Mon. Weather Rev.*. vol. 145. no. 8. pp. 3203–3221. 2017.
- [17] J. Kleine Deters. R. Zalakeviciute. M. Gonzalez. and Y. Rybarczyk. "Modeling PM 2.5 urban pollution using machine learning and selected meteorological parameters." *J. Electr. Comput. Eng.*. vol. 2017. 2017.
- [18] G. Chen *et al.* "A machine learning method to estimate PM2. 5 concentrations across China with remote sensing. meteorological and land use information." *Sci. Total Environ.*. vol. 636. pp. 52–60. 2018.
- [19] J. A. Azevedo. L. Chapman. and C. L. Muller. "Quantifying the daytime and night-time urban heat island in Birmingham. UK: A comparison of satellite derived land surface temperature and high resolution air temperature observations." *Remote Sens.*. vol. 8. no. 2. p. 153. 2016.
- [20] R. Geiger. R. H. Aron. and P. Todhunter. "Ed The climate near the ground." Vieweg: Braunschweig, Germany. 1995.
- [21] M. Kolokotroni and R. Giridharan. "Urban heat island intensity in London: An investigation of the impact of physical characteristics on changes in outdoor air temperature during summer." *Sol. energy*. vol. 82. no. 11. pp. 986–998. 2008.
- [22] A. Shafaghat. G. Manteghi. A. Keyvanfar. H. Bin Lamit. K. Saito. and D. R. Ossen. "Street geometry factors influence urban microclimate in tropical coastal cities: A review." *Environ. Clim. Technol.*. vol. 17. no. 1. pp. 61–75. 2016.
- [23] M. W. Gardner and S. R. Dorling. "Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences." *Atmos. Environ.*. vol. 32. no. 14–15. pp. 2627–2636. 1998.
- [24] D. Cho. C. Yoo. J. Im. and D. Cha. "Comparative assessment of various machine learning-based bias correction methods for numerical weather prediction model forecasts of extreme air temperatures in urban areas." *Earth Sp. Sci.*. vol. 7. no. 4. p. e2019EA000740. 2020.
- [25] J. B. Elsner and A. A. Tsonis. "Nonlinear prediction. chaos. and noise." *Bull. Am. Meteorol. Soc.*. vol. 73. no. 1. pp. 49–60. 1992.
- [26] Ö. A. Dombayıcı and M. Gölcü. "Daily means ambient temperature prediction using artificial neural network method: A case study of Turkey." *Renew. Energy*. vol. 34. no. 4. pp. 1158–1161. 2009.
- [27] D. S. Wilks. *Statistical methods in the atmospheric sciences*. vol. 100. Academic press. 2011.



- [28] K. Patil, M. C. Deo, and M. Ravichandran. "Prediction of sea surface temperature by combining numerical and neural techniques." *J. Atmos. Ocean. Technol.*, vol. 33, no. 8, pp. 1715–1726, 2016.

