

Estimasi Sensor Temperatur Udara *Automatic Weather Station* Menggunakan Algoritma Hybrid Arima-MLP

Suciarti, Masbah R.T Siregar, Abdul Multi, Haryas Subyantara Wicaksana

1 Program Studi Teknik Elektro, Institut Sains dan Teknologi Nasional

Jl. Moh.Kahfi II, Jakarta Selatan

2 Pusat Instrumentasi, Kalibrasi, dan Rekayasa, Badan Meteorologi Kimatologi dan Geofisika

Jl. Angkasa 1 No. 2, Jakarta Pusat

Email: suciarti@bmk.go.id, mrtsiregar2012@istn.ac.id, amulti@istn.ac.id,

Abstract

Air temperature sensor is installed in an enclosure with a relative humidity sensor at a height of 1.25 meters from the ground. This sensor is routinely calibrated every year through a field comparison mechanism using standard portable. However, air temperature sensor has potential to experience troubles due to technical or non-technical factors. Estimation of temperature data can overcome loss data. This study aims to design an estimation model for air temperature sensor data using the ARIMA-MLP hybrid algorithm. Estimated air temperature sensor is focused on AWS Cisarupan in Garut Regency, West Java on 2019. The estimated data has an interval of 10 minutes. Outlier detection uses range check and step check methods. Missing data imputation method utilizes multiple linear regression-based interpolation. ARIMA-MLP hybrid algorithm is able to detect elements of linearity and nonlinearity of air temperature measurements. This algorithm meets WMO requirements regarding air temperature measurements, if training data is used with a minimum percentage of 85% of the entire modeling dataset. The resulting RMSE value is less than 0.2°C.

Keywords: air temperature, Automatic Weather Station, hybrid ARIMA-MLP

Abstrak

Sensor temperatur Automatic Weather Station dipasang dalam satu enclosure dengan sensor kelembapan udara relatif di ketinggian 1,25 meter dari permukaan tanah. Sensor temperatur udara dikalibrasi rutin setiap tahun melalui mekanisme komparasi lapang terhadap AWS portabel standar BMKG. Namun demikian, sensor temperatur berpotensi mengalami kendala pengukuran atau kerusakan saat beroperasi akibat faktor teknis maupun non-teknis. Estimasi data temperatur dapat dilakukan berdasarkan riwayat data sensor maupun data parameter lainnya guna meminimalisir loss data. Penelitian ini bertujuan mendesain model estimasi data sensor temperatur AWS menggunakan algoritma hybrid ARIMA-MLP. Sensor temperatur udara AWS yang diestimasi adalah AWS Cisarupan tahun 2019 di Kabupaten Garut, Jawa Barat. Data yang diestimasi memiliki interval 10 menit. Deteksi outlier menggunakan metode range check dan step check. Metode imputasi missing data menggunakan interpolasi berbasis Multiple Linear Regression. Algoritma hybrid ARIMA-MLP mampu mendeteksi unsur linearitas dan nonlinearitas pengukuran temperatur udara. Algoritma hybrid ARIMA-MLP masih memenuhi persyaratan WMO terkait pengukuran temperatur AWS, jika digunakan data training dengan persentase minimum 85% dari keseluruhan dataset pemodelan. Nilai RMSE yang dihasilkan masih kurang dari 0,2°C.

Kata kunci: temperatur udara, Automatic Weather Station, hybrid ARIMA-MLP

1. Pendahuluan

Automatic Weather Station (AWS) merupakan alat ukur parameter cuaca digital. Parameter cuaca yang diukur meliputi temperatur, kelembapan udara,

tekanan udara, curah hujan, kecepatan dan arah angin serta intensitas radiasi matahari [1]. Temperatur merupakan ukuran aktivitas molekuler suatu partikel. Pergerakan partikel yang semakin cepat

dengan energi kinetis yang besar menyebabkan peningkatan nilai temperatur. Temperatur dapat juga didefinisikan sebagai derajat panas atau dinginnya suatu benda [2]. Temperatur udara memiliki peran cukup krusial dalam menentukan analisis serta prediksi cuaca.

Temperatur udara merupakan temperatur yang diukur oleh termometer yang terpapar oleh udara ruang terbuka di dalam suatu sangkar. Sangkar tersebut melindungi sensor dari radiasi matahari secara langsung [3]. Parameter ini diukur oleh sensor temperatur AWS setiap interval 1 menit, 10 menit, 1 jam dan 1 hari. Sensor temperatur dipasang dalam satu enclosure dengan sensor kelembapan udara relatif di ketinggian 1,25 meter dari permukaan tanah [4].

Sensor temperatur udara dikalibrasi rutin setiap tahun melalui mekanisme komparasi lapang terhadap AWS portabel standar BMKG. Namun demikian, sensor temperatur berpotensi mengalami kendala pengukuran atau kerusakan saat beroperasi akibat faktor teknis maupun non-teknis. Perbaikan atau penggantian sistem sensor memerlukan waktu jeda yang mengakibatkan loss data [5].

Estimasi data temperatur dapat dilakukan berdasarkan riwayat data sensor maupun data parameter lainnya guna meminimalisir loss data. Penelitian ini bertujuan mendesain model estimasi data sensor temperatur AWS menggunakan algoritma hybrid ARIMA-MLP. Selanjutnya, hasil prediksi kedua metode tersebut dibandingkan terhadap data temperatur aktual untuk menilai performa masing-masing metode.

2. Kajian Pustaka

Salcedo-Sanz dkk. mendesain sistem prediksi temperatur udara bulanan di Selandia Baru menggunakan Multi Layer Perceptron (MLP) dengan input data temperatur udara, Southern Oscillation Index (SOI), Indian Ocean Dipole (IOD), dan Pacific Decadal Oscillation (PDO). Namun, resolusi temporal estimasi ini lebih rendah dibanding resolusi temporal pengukuran AWS [6].

Selanjutnya, Rahayu dkk. mendesain sistem prediksi temperatur harian menggunakan Long-Short Term Memory (LSTM) dengan input data temperatur, kelembapan udara, curah hujan dan kecepatan angin. Segmentasi data diuji pada nilai presentase data training dan data uji yang bervariasi. Data input penelitian ini masih bersumber dari pengamatan konvensional dengan resolusi temporal harian [7].

Smith dkk. mendesain sistem estimasi temperatur udara per jam di Georgia menggunakan Multi Layer Perceptron (MLP) dengan input data temperatur udara, kelembapan udara, curah hujan dan intensitas radiasi matahari [8]. Parameter ini identik dengan parameter sensor-sensor AWS. Tran dkk. menyatakan bahwa perlu dilakukan kombinasi antara metode prediksi berbasis Artificial Neural Network (ANN) terhadap metode Auto Regressive Integration Moving Average (ARIMA) guna menjamin akurasi sistem prediksi lebih lanjut [9].

Berdasarkan beberapa penelitian yang dijelaskan, estimasi sensor temperatur memanfaatkan algoritma kecerdasan buatan. Namun demikian, input model estimasi belum melibatkan output AWS secara langsung sebagai instrumen ukur cuaca otomatis. Output sensor temperatur AWS juga memiliki resolusi temporal yang lebih tinggi yaitu per 10 menit. Selain itu, metode berbasis jaringan syaraf tiruan perlu dikomparasi terhadap metode statistik *time series* seperti ARIMA. Penelitian ini berupaya mengkombinasikan model berbasis algoritma ARIMA dan MLP pada estimasi data sensor temperatur AWS.

3. Metode Penelitian

Automatic Weather Station (AWS) mengukur temperatur udara melalui sensor Vaisala HMP155A. Sensor ini merupakan jenis resistance temperature detector (RTD) berbahan platina. Komponen platina yang digunakan memiliki resistansi 100 ohm saat 0° C, sehingga disebut Pt100 [10]. Tipe RTD sensor merupakan *thin film RTD*, yaitu lapisan membran tipis yang terpasang

pada ujung body HMP155A. Nilai resistansi Pt100 (R_T) pada temperatur T tertentu didekati melalui persamaan Callendar-van Dusen, jika ditinjau dari resistansi R_0 ketika 0°C [11] :


$$R_T = R_0(1 + 3,91 \cdot 10^{-3}T - 5,85 \cdot 10^{-7}T^2) \dots \dots \dots (1)$$

Selanjutnya, output resistansi RTD dihubungkan ke *wheatstone bridge* untuk diubah menjadi nilai tegangan DC. *Wheatstone bridge* bertujuan mengkonversi perubahan resistansi pada suatu pengukuran menjadi perubahan nilai tegangan [12]. Nilai output temperatur udara berdasarkan nilai tegangan output pada logger [13]:

$$T_{\text{out}} = \left(\frac{\Delta V_{\text{out}}}{\Delta T} \right) \times V_{\text{out}} + \text{offset} \quad (2)$$

Sensor temperatur udara AWS yang diestimasi adalah AWS Cisirupan di Kabupaten Garut, Jawa Barat. AWS ini diinstal di lingkungan UPTD Balai Benih Kabupaten Garut dan dalam kondisi laik operasional. AWS Cisirupan terletak di koordinat 7,3071 OLS dan 107,79780 BT dengan elevasi 1207 meter di atas permukaan laut. AWS ini terletak di area yang memiliki tipe zona musim (ZOM) monsunial [14].

Data AWS yang digunakan adalah nilai temperatur rata-rata dalam interval setiap 10 menit dalam kurun waktu 1 tahun, yaitu 2019. Jumlah data ideal keseluruhan yaitu 52.560 data. Selain itu, data kelembapan udara relatif, tekanan udara, kecepatan angin dan intensitas radiasi matahari juga dimanfaatkan sebagai data dukung estimator MLP.



Gambar 1. Diagram Alir Pemodelan Estimasi Sensor Temperatur AWS

Gambar 1 menunjukkan diagram alir desain model estimasi temperatur berbasis hybrid ARIMA-MLP. Pra-pemrosesan data dilakukan untuk mendeteksi outlier dan mengisi missing data pada data mentah AWS Cisirupan. Deteksi outlier menggunakan metode *range check* dan *step check*. Range check adalah pengecekan data berdasarkan rentang histori per parameter. Step check adalah pengecekan berdasarkan kaitan temporal data saat ini dengan data sebelumnya [15].

Jika data tidak berada dalam rentang range check atau selisih data terkini dengan data sebelumnya melebihi *step check*, maka data menjadi *suspect*. Data *suspect* berarti data dianggap sebagai outlier. Selanjutnya, outlier dihapus melalui mekanisme listwise deletion per parameter. *Listwise deletion* adalah proses menghapus seluruh data outlier dan missing data [16].

Missing data merupakan data kosong yang terjadi karena ketidaktersediaan data akibat gangguan sistem komunikasi AWS. Imputasi terhadap missing data dilakukan untuk melengkapi data pemodelan estimasi. Metode imputasi missing data menggunakan interpolasi berbasis Multiple Linear Regression [17]. Metode MLR secara matematis dinyatakan sebagai berikut [18] :

$$Y = b_0 + b_1X_1 + \dots + b_kX_k + \epsilon \dots \dots \dots (3)$$

Y menyatakan variabel terikat sebagai output estimasi. b_0 dan b_i menyatakan koefisien korelasi variabel bebas. X_i menyatakan variabel bebas sebagai input estimasi. ϵ menyatakan random error sebagai residu estimasi. MLR dilakukan pada setiap parameter sensor AWS.

Model hybrid yaitu kombinasi dari dua model atau lebih dalam suatu fungsi sistem. Model hybrid ARIMA-ANN adalah model yang mengatasi masalah linier dan nonlinier secara sekuensial. Model ARIMA berfungsi mengestimasi temperatur udara secara linier. Residual ARIMA memuat model non-linier. Jika y_t adalah nilai aktual dan $\hat{L}_t$ adalah nilai estimasi ARIMA, maka nilai residual (e_t) secara matematis dinyatakan sebagai berikut [19]:

$$e_t = y_t - \hat{L}_t \dots\dots\dots(4)$$

Model nonlinear selanjutnya diestimasi menggunakan algoritma MLP. Jika $\hat{N}_t$ adalah estimasi MLP dan b adalah bias MLP, hubungan nilai residual (e_t) apabila dinyatakan dalam fungsi nonlinier MLP diuraikan sebagai berikut:

$$\hat{N}_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + b \dots\dots(5)$$

Selanjutnya, kombinasi estimasi ARIMA dan MLP dijumlahkan untuk menghasilkan nilai estimasi akhir model hybrid. Persamaan estimasi model hybrid dinyatakan:

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \dots\dots\dots(6)$$

Tingkat akurasi hasil prediksi output validasi serta *testing* model ARIMA, MLP dan hybrid ARIMA-MLP dievaluasi menggunakan parameter koefisien determinasi (*R-squared*), *root mean squared error* (RMSE), dan *mean absolute percentage error* (MAPE).

4. Hasil dan Pembahasan

Jumlah data ideal AWS Cisurupan yang seharusnya tersedia untuk setiap sensor yaitu 52.560. Namun demikian, jumlah raw data yang tersedia hanya 52.383. Imputasi data sensor temperatur udara (T) menggunakan metode regresi multilinear berdasarkan input data sensor tekanan udara (P), kecepatan angin (WS) dan intensitas radiasi matahari (SR). Output imputasi sensor temperatur udara diperoleh melalui persamaan regresi multilinear sebagai berikut:


$$T = 0,414 WS + 0,026 P - 0,001 SR - 3,652 \dots\dots\dots(8)$$

Nilai hasil imputasi masih berada dalam rentang QC *range check*. Hasil imputasi mampu mengisi *gap data* terbanyak pada periode Agustus 2019 dengan nilai yang rasional, sehingga tidak menimbulkan *outlier* baru pada dataset pemodelan sensor temperatur. Tabel 1 menunjukkan rincian statistik dataset AWS Cisurupan setelah proses imputasi.

Tabel 1. Karakteristik Statistik Data Sensor AWS Cisurupan 2019

Komponen	Temperatur Udara (°C)	Tekanan Udara (m bar)	Kecepatan Angin (m/s)	Intensitas Radiasi Matahari (W/m ²)
Mean	20,6	887,2	2,2	257,3
Median	20,2	887,2	2,0	460,0
Maksimum	29,9	891,6	7,2	1498,0
Minimum	15,0	882,1	0,0	0,0
Range	14,9	9,5	7,2	1498,0
Simpangan Baku	2,9	1,4	1,0	383,9

Berdasarkan rincian statistik pada Tabel 1, nilai sensor temperatur udara AWS Cisurupan bervariasi antara 15 °C - 29,9 °C sepanjang tahun 2019. Pengujian nilai *Akaike Information Criterion* (AIC) dilakukan terhadap model ARIMA sesuai rentang orde autoregresi (p) dan orde moving average (q).



Gambar 2. Plot AIC Model ARIMA

Nilai AIC dipengaruhi oleh jumlah data observasi dan tingkat kesesuaian prediksi pemodelan. Gambar 2 menunjukkan model ARIMA (4,1,9) memiliki nilai AIC 93622,563. Model ARIMA (4,1,9) memiliki nilai AIC terendah dibanding model lainnya, sehingga model ini diimplementasikan lebih lanjut dalam prediksi output sensor temperatur AWS. Nilai koefisien model ARIMA (4,1,9) secara matematis dijabarkan sebagai berikut:

$$Y_t = 0,3483 + 1,0985Y_{t-1} + 1,7724Y_{t-2} + 0,1034Y_{t-3} - 0,9821Y_{t-4} - 0,2012e_{t-1} - 1,7634e_{t-2} + 0,119e_{t-3} + 0,9952e_{t-4} - 0,1358e_{t-5} + 0,0034e_{t-6} - 0,0139e_{t-7} - 0,0176e_{t-8} + 0,018e_{t-9} \dots\dots\dots(9)$$


Model MLP diadaptasi dari model Roy [20]. Model ini memiliki parameter input yang relatif sama dengan parameter sensor AWS dan nilai hyperparameter

yang sederhana. Tabel 2 menunjukkan struktur hyperparameter model MLP.

Tabel 2. Struktur Hyperparameter model MLP

Versi Model	Jumlah Layer	Jumlah Neuron	Detail Fungsi Aktivasi	Batch Size	Jumlah Epoch
Roy (2020)	3	Layer 1 : 16 Layer 2 : 16 Layer 3 : 1	Layer 1 : relu Layer 2 : relu Layer 3 : linear	32	50

Pemodelan hybrid ARIMA-MLP diawali dengan menganalisis residu model ARIMA (4,1,9). Residu merupakan akumulasi error per titik prediksi pemodelan ARIMA. Nilai ini menjadi indikasi nonlinearitas parameter temperatur udara AWS. Gambar 3 adalah grafik plot residu model ARIMA (4,1,9) sensor temperatur udara AWS Cisarupan.



Gambar 3. Plot Residu Model ARIMA (4,1,9)

Nilai residu selanjutnya digunakan sebagai input model MLP. Prediksi residu berdasarkan MLP bertujuan mendeteksi unsur nonlinearitas pengukuran temperatur serta mengoreksi hasil prediksi model ARIMA (4,1,9). Nilai residu sebagai input MLP dianalisis berdasarkan autoregresi. Hasil AIC menunjukkan residu pada interval (t-1) hingga (t-10) masih bersifat signifikan terhadap pemodelan. Rentang interval residu ini selanjutnya digunakan sebagai input MLP pada model hybrid.

Tabel 3. R^2 Hasil Uji Performa Algoritma Hybrid ARIMA MLP

Data Training	Data Uji	R^2		
		ARIMA	MLP	HYBRID
70%	30%	0,958	0,961	0,994
75%	25%	0,959	0,966	0,994
80%	20%	0,962	0,968	0,994
85%	15%	0,977	0,979	0,996

90%	10%	0,988	0,989	0,997
-----	-----	-------	-------	-------


Tabel 4. RMSE (°C) Hasil Uji Performa Algoritma Hybrid ARIMA MLP

Data Trainin g	Dat a Uji	RMSE (°C)		
		ARIM A	ML P	HYBRI D
70%	30%	4,67	0,66	0,24
75%	25%	4,66	0,66	0,26
80%	20%	4,61	0,58	0,26
85%	15%	4,44	0,49	0,20
90%	10%	4,11	0,30	0,15


Tabel 5. MAPE (%) Hasil Uji Performa Algoritma Hybrid ARIMA MLP

Data Trainin g	Dat a Uji	MAPE (%)		
		ARIM A	ML P	HYBRI D
70%	30%	17,94	1,40	0,72
75%	25%	17,76	1,73	0,65
80%	20%	17,37	1,25	0,65
85%	15%	16,64	1,35	0,55
90%	10%	15,30	0,86	0,48

Tabel 3, 4 dan 5 menunjukkan performa hasil estimasi temperatur udara berbasis algoritma ARIMA, MLP dan Hybrid ARIMA-MLP. Ketiga algoritma menunjukkan koefisien determinasi $R^2 > 0,9$ sehingga cukup berkorelasi erat terhadap pengukuran sensor temperatur aktual. Algoritma hybrid ARIMA-MLP mampu mendeteksi unsur linearitas dan nonlinearitas pengukuran temperatur udara. Sifat nonlinearitas diakibatkan oleh munculnya nilai residu model ARIMA. Estimasi residu MLP mampu menjadi faktor koreksi hasil estimasi model ARIMA. Performa algoritma hybrid ARIMA-MLP menunjukkan nilai RMSE terendah dibanding ARIMA dan MLP jika masing-masing beroperasi *stand alone*. Gambar 4 menunjukkan hasil estimasi ketiga algoritma dalam beberapa segmen waktu.



Gambar 4. Hasil Estimasi Sensor Temperatur Berbasis ARIMA, MLP dan Hybrid



Gambar 5. Hasil Estimasi Sensor Temperatur Berbasis ARIMA, MLP, dan Hybrid

Berdasarkan Gambar 4 dan Gambar 5, pola hasil estimasi ARIMA dan MLP cenderung mendahului pola nilai pengukuran temperatur aktual. Hasil plot ini menunjukkan estimasi hybrid ARIMA-MLP memiliki pola estimasi yang cukup identik dengan pengukuran sensor temperatur aktual. Algoritma hybrid ARIMA-MLP masih memenuhi persyaratan WMO terkait pengukuran temperatur AWS, jika digunakan data training dengan persentase minimum 85% dari keseluruhan dataset pemodelan. Nilai RMSE yang dihasilkan masih kurang dari 0,2°C sesuai ketentuan dokumen WMO No.8.

5. Kesimpulan

Algoritma hybrid ARIMA-MLP mampu mendeteksi unsur linearitas dan nonlinearitas pengukuran temperatur

udara AWS. Performa algoritma hybrid ARIMA-MLP menunjukkan nilai RMSE terendah dibanding ARIMA dan MLP jika beroperasi *stand alone*. Algoritma estimasi ini memenuhi persyaratan ketentuan WMO No.8 terkait pengukuran temperatur udara apabila persentase data training minimum 85%.

Daftar Pustaka

- Badan Meteorologi Klimatologi dan Geofisika. (2014). *Peraturan Kepala BMKG Nomor 7 Tahun 2014 tentang Standar Teknis dan Operasional Pemeliharaan Peralatan Pengamatan Meteorologi, Klimatologi dan Geofisika*.
- Rohli, R. v., & Vega, A. J. (2018). *Climatology* (4th ed.). Jones & Bartlet Learning.
- World Meteorological Organization. (2018). *Guide to Instruments and Methods of Observation Volume I- Measurement of Meteorological Variables*. <https://public.wmo.int/en>
- Battista, P., Maracchi, G., Sabatini, F., Sivakumar, M. V. K., & Zaldei, A. (2000). *Training Center Manual on Instrumentation and Operations for Automatic Weather Stations for Agrometeorological Application*.
- Badan Meteorologi Klimatologi dan Geofisika. (2015). *Peraturan Kepala BMKG Nomor 23 Tahun 2015 tentang Tata Cara Tetap Pelaksanaan Kalibrasi Peralatan Pengamatan Meteorologi, Klimatologi dan Geofisika*.
- Salcedo-Sanz, S., Deo, R. C., Carro-Calvo, L., & Saavedra-Moreno, B. (2016). Monthly prediction of air temperature in Australia and New Zealand with machine learning algorithms. *Theoretical and Applied Climatology*, 125(1-2), 13-25. <https://doi.org/10.1007/s00704-015-1480-4>
- Rahayu, I. S., Djamal, E. C., Ilyas, R., & Talib Bon, A. (2020). Daily Temperature Prediction Using Recurrent Neural Networks and Long-Short Term

- Memory. *Proceedings of the 5 Th NA International Conference on Industrial Engineering and Operations Management*, 2700–2709.
- Smith, B. A., McClendon, R. W., & Hoogenboom, G. (2007). Improving Air Temperature Prediction with Artificial Neural Networks. *International Journal of Computer and Information Engineering*, 1(10), 3146–3153. [scholar.waset.org/1307-6892/10353](https://doi.org/10.1017/pan.2018.18)
- Tran, T. T. K., Bateni, S. M., Ki, S. J., & Vosoughifar, H. (2021). A review of neural networks for air temperature forecasting. In *Water (Switzerland)* (Vol. 13, Issue 9). MDPI AG. <https://doi.org/10.3390/w13091294>
- Fraden, J. (2016). *Handbook of Modern Sensors* (5th ed.). Springer. <https://doi.org/10.1007/978-3-319-19303-8>
- Bentley, J. P. (2005). *Principles of Measurement Systems* (4th ed.). Pearson Education Limited. [www.pearsoned.co.uk](https://doi.org/10.1007/978-3-319-19303-8)
- Liptak, B. G., Raton, B., New, L., & Washington, Y. (2003). *Instrument Engineers' Handbook Process Measurement and Analysis* (4th ed., Vol. 1). CRC Press LLC.
- Scientific, C. (2018). *Operator's Manual CR1000 Datalogger*. [www.campbellsci.com](https://doi.org/10.1007/978-3-319-19303-8).
- Tim Bidang Analisis Variabilitas Iklim Pusat Informasi Perubahan Iklim Kedeputan Klimatologi BMKG. (2022). *Pemutakhiran Zona Musim Indonesia Periode 1991-2020*.
- Fiebrich, C. A., Morgan, Y. R., McCombs, A. G., Hall, P. K., & McPherson, R. A. (2010). Quality assurance procedures for mesoscale meteorological data. *Journal of Atmospheric and Oceanic Technology*, 27(10), 1565–1582. <https://doi.org/10.1175/2010JTECHA1433.1>
- Pepinsky, T. B. (2018). A Note on Listwise Deletion versus Multiple Imputation. *Political Analysis*, 26(4), 480–488. <https://doi.org/10.1017/pan.2018.18>
- Kotsiantis, S., Kostoulas, A., Lykoudis, S., Argiriou, A., & Menagias, K. (2006). Filling missing temperature values in weather data banks. *IET Conference Publications*, 518, 327–334. <https://doi.org/10.1049/cp:20060659>
- Uyanık, G. K., & Güler, N. (2013). A Study on Multiple Linear Regression Analysis. *Procedia - Social and Behavioral Sciences*, 106, 234–240. <https://doi.org/10.1016/j.sbspro.2013.12.027>
- Parasyris, A., Alexandrakakis, G., Kozyrakis, G. v., Spanoudaki, K., & Kampanis, N. A. (2022). Predicting Meteorological Variables on Local Level with SARIMA, LSTM and Hybrid Techniques. *Atmosphere*, 13(6). <https://doi.org/10.3390/atmos13060878>
- Roy, D. S. (2020). Forecasting the Air Temperature at a Weather Station Using Deep Neural Networks. *Procedia Computer Science*, 178, 38–46. <https://doi.org/10.1016/j.procs.2020.11.005>