

Implementasi Sliding Window Algorithm pada Prediksi Kurs berbasis Neural Network

Primandani Arsi¹, Tri Astuti², Desty Rahmawati³, Pungkas Subarkah⁴

^{1,2,3}informatika, Fakultas Ilmu Komputer, Universitas Amikom Purwokerto

email: ukhti.prima@amikompurwokerto.ac.id¹, tri_astuti@amikompurwokerto.ac.id²,

desty@amikompurwokerto.ac.id³, subarkah@amikompurwokerto.ac.id⁴

Abstract: Time series is sequential data based on time sequence. Time series data can be used for prediction topics, one of the prediction topics that is always interesting to study is exchange rate prediction. In the case of exchange rate prediction, an appropriate data preprocessing stage is required. The success of this preprocessing stage will have a major effect on the resulting RMSE value. There is an important technique in determining the best RMSE value, especially in time series data, one of which is the windowing technique. The windowing technique is the stage of transforming time series data into cross sectional. Window size has an important role in time series data. However, there is no standard in window size. The Window size experiment starts with a small value and then increases to a larger value until it reaches a certain point with the best RMSE. In this research, an experiment will be conducted on windows size on exchange rate data based on a neural network. The purpose of this research is to optimize the RMSE of a data mining model based on windows parameters. The implementation of sliding windows is carried out in the scenarios of window sizes 4, 6, and 28. Based on the experiments conducted, the best RMSE is on windows size 6 = 0.014 +/- 0.000. With a combination of neural network parameters in the form of training cycles = 1000, learning rate = 0.1 and momentum = 0.1.

Keywords: Sliding window, Window size, exchange rate, Neural network, RMSE

Abstrak: Data time series ialah kumpulan data yang beruntun/teratur berdasarkan urutan waktu. Data time series dapat digunakan pada topik prediksi, salah satu topik prediksi yang selalu menarik dikaji adalah prediksi kurs. Dalam kasus prediksi kurs dibutuhkan tahapan preprocessing data yang tepat. Keberhasilan tahapan preprocessing inilah yang nantinya berpengaruh besar dalam nilai RMSE yang dihasilkan. Terdapat sebuah teknik penting dalam menentukan nilai RMSE terbaik khususnya pada data time series, salah satunya adalah teknik windowing. Teknik windowing merupakan tahap transformasi data time series menjadi crosssectional. Window size memiliki peran penting pada data time series. Namun tidak ada standart baku dalam ukuran window itu sendiri. Eksperimen Window size diawali dari nilai kecil kemudian ditingkatkan ke nilai yang lebih besar hingga mencapai titik tertentu dengan RMSE terbaik. Dalam penelitian ini akan dilakukan eksperimen terhadap windows size pada data kurs berdasarkan neural network. Tujuan dari penelitian yang dilakukan adalah untuk optimalisasi RMSE dari model data mining berbasis parameter windows. Implementasi sliding windows dilakukan pada skenario window size 4, 6, dan 28. Berdasarkan eksperimen yang dilakukan, RMSE terbaik yakni pada windows size 6 = 0.014 +/- 0.000. Dengan kombinasi dari parameter neural network berupa training cycles=1000, learning rate=0,1 dan momentum=0,1.

Kata kunci: Sliding window, Window size, Kurs, Neural network, RMSE

Pendahuluan

Data time series ialah kumpulan data yang beruntun/teratur berdasarkan urutan waktu. Frekuensi dari urutan waktu tersebut dapat meliputi tahun, bulan, jam, atau bahkan detik (Pérez-Chacón, Asencio-Cortés, Martínez-Álvarez, & Troncoso, 2020) Data time series dapat digunakan pada

topik prediksi, salah satu topik prediksi yang selalu menarik dikaji adalah prediksi kurs (Panda, Panda, & Pattnaik, 2022). Dalam kasus prediksi kurs dibutuhkan tahapan preprocessing data yang tepat. Umumnya tahapan preprocessing data yang dilakukan adalah cleaning, integration, transformation dan reduction (Ćalasan,

Abdel Aleem, & Zobaa, 2020). Keberhasilan tahapan preprocessing inilah yang nantinya berpengaruh besar dalam nilai RMSE yang dihasilkan.

Root Mean Square Error atau sering disebut RMSE adalah sebuah metode pengukuran dengan cara mengukur perbedaan nilai hasil prediksi suatu model, sebagai estimasi dari nilai yang telah diobservasi (Tomar, Tomar, Bhardwaj, & Sinha, 2022). Root Mean Square Error merupakan hasil akar kuadrat dari Mean Square Error (MSE). Keakuratan sebuah metode estimasi atau eror hasil pengukuran ditandai dengan nilai RMSE yang kecil (Hodson, 2022). Sehingga dapat dikatakan sebuah model estimasi dengan RMSE lebih kecil lebih akurat dari pada model estimasi dengan RMSE yang lebih besar (Gao, Xu, & Li, 2022).

Terdapat sebuah teknik penting dalam menentukan nilai RMSE terbaik khususnya pada data time series, salah satunya adalah teknik windowing. Teknik windowing merupakan tahap transformasi data time series menjadi crosssectional (Aulia et al., 2021)(Norwawi, 2021). Berdasarkan penelitian sebelumnya, window size memiliki peran penting pada data time series. Namun tidak ada standart baku dalam ukuran window itu sendiri (Ranjan, Tripathy, Prusty, & Jena, 2021). Eksperimen Window size diawali dari nilai kecil kemudian ditingkatkan ke nilai yang lebih besar hingga mencapai titik tertentu dengan RMSE terbaik (Kulanuwat et al., 2021).

Penelitian yang dilakukan oleh Wahyuni pada tahun 2021 menggunakan window size 6, window size 12 dan window size 18 yang di implementasikan pada prediksi inflasi berbasis neural network. Berdasarkan eksperimen yang dilakukan penulis mendapatkan nilai RMSE optimal pada window size 6 yakni 0,435 (Wahyuni, 2021). Penelitian selanjutnya oleh Soemantri pada tahun 2021 dimana objek penelitian tersebut adalah data gempa bumi yang berasal dari BMKG

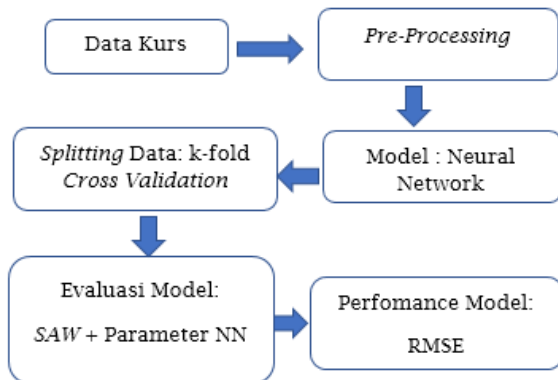
Indonesia. Eksperimen dilakukan dengan membandingkan ukuran windows 4 dan 3. Adapun hasil terbaik adalah pada ukuwan windows 4 dengan RMSE 0,712 (Somantri et al., 2022). Penelitian selanjutnya adalah pada prediksi permukaan air menggunakan Neural Network. Dalam penelitian tersebut optimasi nilai RMSE dilakukan dengan melakukan eksperimen Sliding Window. Eksperimen dilakukan sebanyak 4 kali dengan ukuran window yang berbeda yakni window size 7, window size 14, window size 21 dan window size 28. Ukuran window tersebut merupakan representasi hari sebagai variabel masukan arsitektur jaringan BPNN. Adapun RMSE terbaik diperoleh dengan ukuran window 28 (Dwi Kartini, Friska Abadi, & Triando Hamonangan Saragih, 2021).

Berdasarkan uraian latar belakang diatas terkait dengan pentingnya ukuran window yang dapat mempengaruhi ketepatan hasil prediksi. Maka dalam penelitian ini akan dilakukan eksperimen terhadap windows size pada data kurs berbasis neural network. Tujuan dari penelitian yang dilakukan adalah untuk optimalisasi RMSE dari model data mining berbasis parameter window.

Metode

Implementasi Slidding Windows pada prediksi kurs berbasis neural network dilakukan dengan beberapa tahapan. Adapun setiap tahapan yang dilakukan merupakan upaya untuk menekan tingkat error hasil prediksi seperti yang nampak pada gambar 1 berikut. Tahapan yang pertama kali dilakukan adalah pencarian dataset dari sumber yang valid. Selanjutnya tahapan preprocessing dilakukan untuk mentransformasi data time series menjadi data *crsossectional*. Data tersebut selanjutnya dimodelkan pada neural network dengan beberapa kombinasi parameter yang disesuaikan. Splitting dataset dalam penelitian ini

menggunakan teknik k-fold cross validation, dengan membagi data menjadi 9 bagian untuk data training dan 1 bagian untuk testing. Tahap evaluasi model dilakukan dengan eksperimen sliding window algorithm dan parameter neural network. Performance model dilakukan dengan mengukur tingkat error terkecil (RMSE).



Gambar 1. Tahapan penelitian

1. Dataset dan Preprocessing

Dataset yang digunakan sebagai objek dalam penelitian ini merupakan data yang resmi dipublikasikan oleh Bank Indonesia (Indonesia, n.d.). Dataset tersebut merupakan data kurs rupiah terhadap dolar dengan periode data 2 Januari 2015 hingga 31 Maret 2022. Data yang dimaksud bertipe time series sehingga diperlukan transformasi data dalam bentuk cross-sectional. Pada tahap preprocessing normalisasi data dibutuhkan guna menghilangkan redundansi serta memastikan dependensi pada data dengan range terendah 0,0 dan tertinggi 1,0.

2. Sliding Window Algorithm

Sliding window algorithm merupakan teknik pembentukan struktur pada data time series. Dalam penelitian ini windowing dilakukan untuk mentransformasi data time series menjadi data cross-sectional. Eksperimen Sliding window dilakukan dengan beberapa skenario, sebagaimana hasil eksperimen terbaik

yang terdapat pada penelitian sebelumnya maka skenario dilakukan dengan window size 6, 4 dan 28. Tujuannya adalah mengurangi tingkat kesalahan aproksimasi. Kesalahan pada batas tersebut diwakili oleh beberapa parameter time series (Ding & Fei, 2013). Selanjutnya hasil segmentasi data dimodelkan menggunakan algoritma neural network.

3. Neural Network

Eksperimen dilakukan terhadap dataset menggunakan algoritma neural network. Berdasarkan beberapa penelitian yang telah dilakukan sebelumnya, neural network mampu memprediksi dengan hasil yang baik terutama pada bidang keuangan seperti pergerakan saham, prediksi penjualan dan nilai tukar (Moghaddam, Moghaddam, & Esfandyari, 2016). Pada kasus prediksi nilai tukar, penulis telah melakukan eksperimen pada penelitian sebelumnya menggunakan neural network, namun parameter windows size belum dapat terimplementasi dengan baik (Arsi & Prayogi, 2020). Dalam penelitian kali ini eksperimen windows size akan coba dilakukan berbasis algoritma neural network. Adapun parameter neural network yang menjadi objek eksperimen adalah training cycles, momentum, learning rate. Masing-masing parameter akan dilakukan eksperimen dengan skenario training cycles 100 hingga 2000; skenario learning rate 0,1 hingga 1; momentum dengan range 0,1 hingga 0,9. Splitting data dilakukan untuk menentukan pembagian jumlah data latih serta data uji. Splitting dilakukan dengan menerapkan teknik k-Fold Cross Validation.

4. RMSE (Root Mean Square Error)

Performance model terbaik diukur dengan RMSE dan MSE pada hasil prediksi. Root Mean Squared Error

(RMSE) merupakan metode untuk mengevaluasi model dengan cara mengukur tingkat akurasi dari hasil perkiraan model yang dihasilkan. RMSE dievaluasi dengan cara melakukan perhitungan kuadrat error (prediksi - observasi) dibagi dengan total data (= rata-rata), kemudian diakarkan. Sedangkan MSE merupakan rerata dari eror kuadrat antara nilai aktual dan nilai prediksi dibagi jumlah data, sebagaimana dirumuskan dalam persamaan dibawah ini(Chicco, Warrens, & Jurman, 2021).

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \tag{1}$$

$$MSE = \sum \frac{(\hat{y} - y)^2}{n} \tag{2}$$

Hasil

Data yang telah dihimpun dari Bank Indonesia sejumlah 1.535 dengan periode data 2 Januari 2015 hingga 31 Maret 2021. Data terdiri dari 5 variabel yakni id; nilai; kurs jual; kurs beli; dan tanggal. Preprocessing awal pada data menghasilkan dua buah variabel yakni “date” dan “kurs” yang selanjutnya digunakan pada tahap berikutnya (disajikan pada tabel 1).

Tabel 1. Data mentah

Kurs	Date
14.572	31 Maret 2021
14.481	30 Maret 2021
14.434	29 Maret 2021
14.446	26 Maret 2021
14.464	25 Maret 2021
14.455	24 Maret 2021
14.421	23 Maret 2021
14.456	22 Maret 2021
14.476	19 Maret 2021
14.572	31 Maret 2021
.....
12.589	5 Januari 2015
12.474	2 Januari 2015

Dalam penelitian ini normalisasi dilakukan guna meminimalisir redudansi data dan mencegah anomali pada data. Normalisasi dilakuan dengan range minimal 0,0 sedangkan maximal 1,0 seperti yang terlihat pada tabel 2 berikut.

Tabel 2. Data setelah dinormalisasi

Kurs	Date
0.49522922969513616	31 Maret 2021
0.47405166395159415	30 Maret 2021
0.4631138003258087	29 Maret 2021
0.4659064463579241	26 Maret 2021
0.4700954154060973	25 Maret 2021
0.4680009308820107	24 Maret 2021
0.460088433791017	23 Maret 2021
0.468233651384687	22 Maret 2021
0.4728880614382127	19 Maret 2021
0.45799394926693043	31 Maret 2021
.....
0.03374447288806144	5 Januari 2015
0.006981615080288574	2 Januari 2015

1. Implementasi Neural Network

Implementasi neural network terhadap dataset yang digunakan dilakukan dengan 3 tahap eksperimen yakni taining cycles; learning rate; momentum, adapun hasil eksperimen dapat dilihat pada tabel dibawah ini.

Tabel 3. Eksperimen parameter training cycles

Training cycles	RMSE
200	0.017 +/- 0.002
400	0.017 +/- 0.002
600	0.017 +/- 0.002
800	0.017 +/- 0.002
1000	0.016 +/- 0.002
1200	0.016 +/- 0.002
1400	0.016 +/- 0.002
1600	0.016 +/- 0.002
1800	0.016 +/- 0.002
2000	0.016 +/- 0.002

Eksperimen parameter training cycles dengan skenario 200 hingga 2000, dengan learning rate=0,1 dan momentum=0,1 menunjukkan adanya persamaan nilai RMSE pada training cycles 200 sampai dengan 800 yakni

0.017 +/- 0.002. Sementara itu terjadi penurunan nilai RMSE pada nilai training cycles 1000 dengan nilai RMSE 0.016 +/- 0.002, nilai RMSE tersebut tidak mengalami perubahan sampai dengan eksperimen terakhir yakni training cycles 2000. Selanjutnya dengan menggunakan parameter training cycles 1000 ditetapkan untuk eksperimen learning rate, dengan range eksperimen antara 0,1 hingga 1 sedangkan nilai momentum 0,1. Eksperimen yang dihasilkan ditunjukkan dalam dalam tabel 4.

Tabel 4. Eksperimen parameter learning rate

Training cycles	Learning rate	RMSE
1000	0,1	0.016 +/- 0.002
1000	0,2	0.017 +/- 0.003
1000	0,3	0.018 +/- 0.003
1000	0,4	0.019 +/- 0.005
1000	0,5	0.019 +/- 0.006
1000	0,6	0.021 +/- 0.009
1000	0,7	0.022 +/- 0.011
1000	0,8	0.028 +/- 0.015
1000	0,9	0.028 +/- 0.015
1000	1	0.037 +/- 0.015

Berdasarkan eksperimen yang dilakukan terhadap parameter learning rate seperti yang tampak pada tabel 4 diatas, menunjukkan bahwa semakin tinggi learning rate maka semakin tinggi eror yang dihasilkan. Learning rate dengan hasil RMSE terbaik adalah 0,1 dengan RMSE 0.017 +/- 0.002. Eksperimen berikutnya dengan menetapkan training cycles 1000 dan learning 0,1 dilakukan untuk eksperimen momentum.


Tabel 5. Eksperimen parameter momentum

Training cycles	Learning rate	Momentum	RMSE
1000	0,1	0,1	0.016 +/- 0.002
1000	0,1	0,2	0.017 +/- 0.002
1000	0,1	0,3	0.017 +/- 0.002
1000	0,1	0,4	0.017 +/- 0.002

1000	0,1	0,5	0.017 +/- 0.002
1000	0,1	0,6	0.017 +/- 0.003
1000	0,1	0,7	0.018 +/- 0.003
1000	0,1	0,8	0.018 +/- 0.004
1000	0,1	0,9	0.021 +/- 0.005

Tabel 5 diatas menunjukkan hasil eksperimen pada parameter momentum. Momentum 0,1 menghasilkan RMSE paling kecil yakni 0.016 +/- 0.002. Pada momentum 0,2 hingga 0,5 tidak terjadi perubahan pada RMSE, namun pada nilai momentum 0,6 terjadi perubahan pada toleransi error yakni dari 0.017 +/- 0.002 menjadi 0.017 +/- 0.003. Perubahan RMSE kembali terjadi pada momentum 0,7 hingga 0,9. Sehingga dapat disimpulkan bahwa hasil RMSE terbaik melalui eksperimen momentum adalah pada nilai 0,1.

Berdasarkan eksperimen yang dilakukan terhadap beberapa parameter neural network maka mendapatkan kombinasi parameter neural network terbaik pada training cycles=1000, learning rate=0,1 dan momentum=0,1, dengan arsitektur neural network seperti yang tampak pada gambar 1 dibawah ini.




Gambar 2. Arsitektur neural network

2. Implementasi Sliding Window Algorithm

Pada data kurs yang digunakan, data ke 1 sampai dengan 1.535 merupakan unit observasi. Segmen pertama adalah data ke 1 hingga data ke 6, digunakan pada prediksi data ke 7.

Segmen kedua adalah data ke 2 hingga ke 7, digunakan pada prediksi data ke 8. Proses tersebut terus berlanjut hingga data selesai tersegmentasi dengan baik seperti yang tampak pada gambar 2 berikut. Segmentasi window size 6 menghasilkan 510 rows dari 1.535 data. Hasil segmentasi window pada window size 6 disajikan pada tabel 7.



Tabel 7. Hasil segmentasi dari window size 6

id	Ku rs + 1	Ku rs- 5	Ku rs- 4	Ku rs- 3	Ku rs- 2	Ku rs- 1	Ku rs- 0
0	0,4 60	0,4 95	0,4 74	0,4 63	0,4 66	0,4 70	0,4 68
1	0,4 58	0,4 66	0,4 70	0,4 68	0,4 60	0,4 68	0,4 73
2	0,4 59	0,4 60	0,4 68	0,4 73	0,4 58	0,4 69	0,4 61
3	0,4 60	0,4 58	0,4 69	0,4 61	0,4 59	0,4 48	0,4 60
4	0,4 48	0,4 59	0,4 48	0,4 60	0,4 60	0,4 71	0,4 53
5	0,4 34	0,4 60	0,4 71	0,4 53	0,4 48	0,4 32	0,4 40
6	0,3 86	0,4 48	0,4 32	0,4 40	0,4 34	0,4 32	0,4 15
7	0,3 85	0,4 34	0,4 32	0,4 15	0,3 86	0,3 83	0,3 91
8	0,3 67	0,3 86	0,3 83	0,3 91	0,3 85	0,3 82	0,3 76
9	0,3 65	0,3 85	0,3 82	0,3 76	0,3 67	0,3 33	0,3 50
10	0,3 62	0,3 67	0,3 33	0,3 50	0,3 65	0,3 65	0,3 60
11	0,3 70	0,3 65	0,3 65	0,3 60	0,3 62	0,3 62	0,3 77
12	0,3 72	0,3 62	0,3 62	0,3 77	0,3 70	0,3 66	0,3 72
13	0,3 83	0,3 70	0,3 66	0,3 72	0,3 72	0,3 82	0,3 90

1	0,3	0,3	0,3	0,3	0,3	0,3	0,3
4	75	72	82	90	83	82	81
1	0,3	0,3	0,3	0,3	0,3	0,3	0,3
5	82	83	82	81	75	71	77
1	0,3	0,3	0,3	0,3	0,3	0,3	0,3
6	90	75	71	77	82	81	78
....
..
5	0,0	0,0	0,0	0,0	0,0	0,0	0,0
0	29	50	39	35	40	32	38
7							
5	0,0	0,0	0,0	0,0	0,0	0,0	0,0
0	67	40	32	38	29	46	67
8							
5	0,0	0,0	0,0	0,0	0,0	0,0	0,0
0	07	29	46	67	67	50	34
9							

Implementasi sliding windows dilakukan pada skenario window size 4, 6, dan 28. Tabel dibawah ini merupakan hasil eksperimen pada window size 4, 6 dan 28. Eksperimen dilakukan dengan mengimplementasikan k-fold validation pada tiap window size. Berdasarkan eksperimen, ditunjukkan bahwa RMSE terbaik pada window size 6 dengan nilai k=3 RMSE 0.014 +/- 0.000.

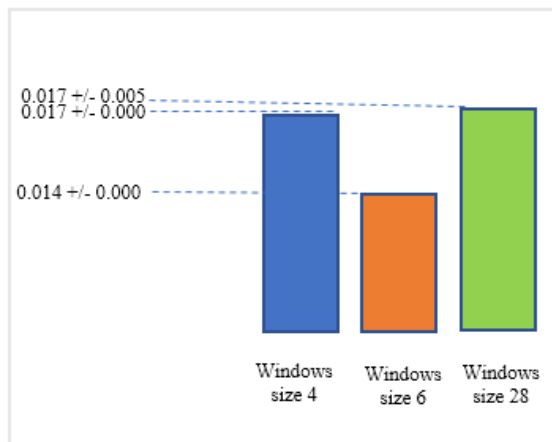
Tabel 6. Ekperimen window size 4 dengan implementasi k-fold

k-fold	RMSE		
	Window size 4	Window size 6	Window size 28
2	0.017 +/- 0.000	0.015 +/- 0.000	0.019 +/- 0.000
3	0.018 +/- 0.002	0.014 +/- 0.000	0.019 +/- 0.001
4	0.017 +/- 0.003	0.016 +/- 0.002	0.018 +/- 0.002
5	0.019 +/- 0.005	0.015 +/- 0.002	0.018 +/- 0.003

6	0.017 +/- 0.002	0.016 +/-0.002	0.020 +/- 0.004
7	0.018 +/- 0.004	0.015 +/- 0.003	0.019 +/- 0.006
8	0.018 +/- 0.003	0.016 +/- 0.003	0.020 +/- 0.004
9	0.018 +/- 0.005	0.015 +/- 0.002	0.017 +/- 0.005
10	0.017 +/- 0.004	0.015 +/- 0.002	0.020 +/- 0.005

Evaluasi Model

Pencarian model terbaik dengan optimasi Sliding windows algorithm pada model menghasilkan RMSE yang bervariasi. Guna membandingkan model berdasarkan parameter window dapat divisualisasikan pada melalui gambar berikut.



Gambar 4. Evaluasi model dengan RMSE terbaik

Pada gambar diatas ditampilkan hasil evaluadi model berdasarkan RMSE terbaik yakni pada windows size 6 = 0.014 +/- 0.000. Dengan kombinasi dari parameter neural network berupa training cycles=1000, learning rate=0,1 dan momentum=0,1.

Simpulan

Optimasi dengan metode Sliding Window Algorithm mampu meningkatkan akurasi pada prediksi kurs rupiah berbasis neural network. Hal ini ditunjukkan dengan nilai RMSE yang mengecil pada windows size 6 = 0.014 +/- 0.000. Ketepatan ukuran segmentasi windows berpengaruh secara signifikan pada prediksi dengan data time series berbasis neural network. Namun masih terdapat kekurangan pada eksperimen parameter neural network. Kombinasi parameter neural network perlu eksperimen yang tepat untuk mendapatkan RMSE terbaik. Diharapkan pada penelitian selanjutnya dilakukan metode optimasi berbasis parameter neural network yang nantinya akan berpengaruh juga pada RMSE yang dihasilkan.

Daftar Pustaka

- Arsi, P., & Prayogi, J. (2020). Optimasi Prediksi NilaiTukar Rupiah Terhadap Dolar Menggunakan Neural Network Berbasiskan Algoritma Genetika. *Jurnal Informatika*, 7(1), 8-14. <https://doi.org/10.31311/ji.v7i1.6793>
- Aulia, A. A., Elhanafi, A. M., Dafitri, H., Aulia, A., Elhanafi, A. M., & Dafitri, H. (2021). Implementasi Algoritma Gated Recurrent Unit Dalam Melakukan Prediksi Harga Kelapa Sawit Dengan Memanfaatkan Model Recurrent Neural Network (RNN). *Prosiding SNASTIKOM: Seminar Nasional Teknologi Informasi & Komunikasi Paper*, 288-294.
- Ćalasan, M., Abdel Aleem, S. H. E., & Zobia, A. F. (2020). On the root mean square error (RMSE) calculation for parameter estimation of photovoltaic models: A novel exact analytical solution based on Lambert W function. *Energy Conversion and Management*, 210(January),

112716.
<https://doi.org/10.1016/j.enconman.2020.112716>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, 1-24. <https://doi.org/10.7717/PEERJ-CS.623>
- Ding, Z., & Fei, M. (2013). *An anomaly detection approach based on isolation forest algorithm for streaming data using sliding window*. *IFAC Proceedings Volumes (IFAC-PapersOnline)* (Vol. 3). IFAC. <https://doi.org/10.3182/20130902-3-CN-3020.00044>
- Dwi Kartini, Friska Abadi, & Triando Hamonangan Saragih. (2021). Prediksi Tinggi Permukaan Air Waduk Menggunakan Artificial Neural Network Berbasis Sliding Window. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1), 39-44. <https://doi.org/10.29207/resti.v5i1.2602>
- Gao, Q., Xu, H., & Li, A. (2022). The analysis of commodity demand predication in supply chain network based on particle swarm optimization algorithm. *Journal of Computational and Applied Mathematics*, 400, 113760. <https://doi.org/10.1016/j.cam.2021.113760>
- Hodson, T. O. (2022). Root Mean Square Error (RMSE) or Mean Absolute Error (MAE): when to use them or not. *Geoscientific Model Development*, 7(March), 1525-1534.
- Indonesia, B. (n.d.). Data Kurs Rupiah - Dolar. Retrieved from <https://www.bi.go.id/>
- Kulanuwat, L., Chantrapornchai, C., Maleewong, M., Wongchaisuwat, P., Wimala, S., Sarinnapakorn, K., & Boonya-Aroonnet, S. (2021). Anomaly detection using a sliding window technique and data imputation with machine learning for hydrological time series. *Water (Switzerland)*, 13(13). <https://doi.org/10.3390/w13131862>
- Moghaddam, A. H., Moghaddam, M. H., & Esfandyari, M. (2016). Stock market index prediction using artificial neural network. *Journal of Economics, Finance and Administrative Science*, 21(41), 89-93. <https://doi.org/10.1016/j.jefas.2016.07.002>
- Norwawi, N. M. (2021). *Sliding window time series forecasting with multilayer perceptron and multiregression of COVID-19 outbreak in Malaysia*. *Data Science for COVID-19 Volume 1: Computational Perspectives*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-824536-1.00025-3>
- Panda, M. M., Panda, S. N., & Pattnaik, P. K. (2022). Multi currency exchange rate prediction using convolutional neural network. In *Materials Today: Proceedings*. Elsevier Ltd. <https://doi.org/10.1016/j.matpr.2020.11.317>
- Pérez-Chacón, R., Asencio-Cortés, G., Martínez-Álvarez, F., & Troncoso, A. (2020). Big data time series forecasting based on pattern sequence similarity and its application to the electricity demand. *Inf. Sci. (Ny)*, 540, 160-174.
- Ranjan, K. G., Tripathy, D. S., Prusty, B. R., & Jena, D. (2021). An improved sliding window prediction-based outlier detection and correction for volatile time-series. *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, 34(1), 1-13. <https://doi.org/10.1002/jnm.281>

6

- Somantri, O., Purwaningrum, S., Informatika, J. T., Cilacap, P. N., Studi, P., & Informatika, M. (2022). Model Support Vector Machine (Svm) Berdasarkan Parameter, 8, 17-24.
- Tomar, D., Tomar, P., Bhardwaj, A., & Sinha, G. R. (2022). Deep Learning Neural Network Prediction System Enhanced with Best Window Size in Sliding Window Algorithm for Predicting Domestic Power Consumption in a Residential Building. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/7216959>
- Wahyuni, R. E. (2021). Optimasi Prediksi Inflasi Dengan Neural Network Pada Tahap Windowing Adakah Pengaruh Perbedaan Window Size? *Technologia: Jurnal Ilmiah*, 12(3), 176. <https://doi.org/10.31602/tji.v12i3.5181>