

Penerapan Metode Stacking Untuk Meningkatkan Akurasi Hasil Peramalan Konsumsi Listrik

Nurfia Oktaviani Syamsiah^{1*}, Indah Purwandani²
Fakultas Teknik dan Informatika Universitas Bina Sarana Informatika
¹nurfia.nos@bsi.ac.id, ²indah@bsi.ac.id

Abstrak

Peramalan merupakan salah satu upaya yang sering dilakukan oleh setiap institusi dengan berbagai bidang usaha. Konsumsi listrik menjadi permasalahan yang memerlukan penyelesaian dalam bentuk sebuah model peramalan. Data konsumsi listrik berbentuk data runtun waktu yang ketika digunakan untuk peramalan dapat berupa data univariat maupun data multivariat. Peramalan menggunakan data univariat akan dilakukan dalam penelitian ini dengan memanfaatkan metode *stacking* dengan harapan dapat menghasilkan nilai RMSE yang rendah sehingga akurasi hasil penelitian menjadi lebih baik. Selain itu metode *stacking* juga akan diterapkan untuk tiga interval data berbeda untuk mengetahui tipe interval yang mampu memberikan nilai error terkecil. Berdasarkan hasil penelitian didapatkan bahwa penerapan *stacking* mampu menurunkan nilai RMSE sebesar 0,7%. Selain itu dihasilkan juga fakta bahwa interval data terpendek lebih mampu memberikan RMSE terkecil dengan perbedaan sekitar 7% dengan interval yang lebih panjang.

Kata Kunci: listrik, *stacking*, univariat

Abstract

Forecasting is one effort that is often carried out by every institution with various business fields. Electricity consumption is a problem that requires a solution in the form of a forecasting model. The electricity consumption data is in the form of time series data which when used for forecasting can be in the form of univariate data or multivariate data. Forecasting using univariate data will be carried out in this study by utilizing the stacking method with the hope of producing a low RMSE value so that the accuracy of the research results becomes better. Besides that, the stacking method will also be applied to three different data intervals to find out the type of interval that is able to provide the smallest error value. Based on the research results, it was found that the application of stacking was able to reduce the RMSE value by 0.7%. In addition, the fact is also generated that the shortest data interval is better able to provide the smallest RMSE with a difference of about 7% with a longer interval.

Key Word: electricity, stacking, univariat

1. Pendahuluan

Peramalan merupakan sebuah usaha untuk memprediksi kondisi masa depan dengan akurat, dengan menggunakan beberapa hal yakni informasi yang tersedia, data historis serta pengetahuan terkait kondisi masa depan ataupun segala hal yang akan mempengaruhi hasil peramalan (Hyndman & Athanasopoulos, 2018). Peramalan dapat pula didefinisikan sebagai mekanisme memperoleh interval berdasarkan data saat ini maupun data masa lalu, dengan tujuan didapatkan tren masa depan (Ahmad & Chen,

2020). Singkatnya peramalan merupakan upaya memperkirakan kemungkinan peristiwa yang mungkin terjadi selama jangka waktu tertentu.

Peramalan menjadi suatu hal yang dibutuhkan dalam banyak kondisi dan situasi, seperti keputusan untuk menambah kapasitas produksi beberapa tahun ke depan memerlukan peramalan konsumsi, penentuan lokasi kegiatan memerlukan peramalan kondisi cuaca, perluasan gedung kuliah memerlukan peramalan jumlah mahasiswa dan dosen. Beberapa penelitian peramalan telah banyak dilakukan sebelumnya dengan memanfaatkan berbagai metode (Petropoulos et al., 2018) (Naim & Mahara, 2018) (Syamsiah, 2020) (Phan, 2018) .

Salah satu hal yang sangat terakit dengan proses peramalan adalah data runtun waktu. Data jenis ini dicatat berdasarkan urutan waktu dan terbagi menjadi dua jenis yakni, runtun waktu multivariat dan runtun waktu univariat. Runtun waktu multivariat memiliki beberapa variabel yang diamati, tetapi runtun waktu univariat memiliki satu variabel yang diamati. Pada dasarnya data runtun waktu memiliki karakteristik unik seperti jumlah data yang besar, adanya *noise* secara acak, dan hubungan non linier pada elemen data. Jenis data ini dihasilkan secara kronologis dan memiliki karakteristik berdimensi tinggi dengan ketergantungan temporal. Yang dimaksud dimensi tinggi disini adalah bahwasanya setiap titik waktu akan menjadi sebuah dimensi, sedangkan maksud dari ketergantungan temporal adalah jika terdapat dua titik yang identik secara numerik maka bisa saja termasuk dalam kelas yang berbeda atau dapat juga memprediksi perilaku yang berbeda.

Data runtun waktu telah banyak dipelajari dan diteliti dan salah satunya adalah dalam bidang peramalan. Peramalan yang akurat akan membawa banyak keuntungan seperti kinerja perencanaan produksi yang baik, penurunan biaya operasi atau perencanaan untuk melindungi masalah masa depan secara efisien (Chuentawat & Kangan, 2018). Peramalan runtun waktu univariat dapat menjadi tantangan, terutama karena ada perbedaan antara kehidupan nyata dengan asumsi yang biasanya muncul karena penerapan suatu model dalam sistem pendukung peramalan. Peramalan runtun waktu telah menjadi sebuah sub bidang penelitian di beberapa dekade ini, kondisi tersebut diikuti dengan berbagai model statistik dan algoritma komputasi canggih yang telah dikembangkan untuk meningkatkan akurasi. Untuk prediksi jangka pendek, runtun waktu univariat lebih unggul daripada multivariat, sedangkan untuk prediksi jangka panjang atau dengan tingkat gangguan pengamatan yang besar, prediksi multivariat bekerja lebih baik daripada prediksi univariate (Chayama & Hirata, 2016).

Dua metode yang banyak digunakan dalam peramalan adalah statistik dan *Machine Learning* (ML), terdapat perbedaan mendasar pada keduanya yaitu ML memanfaatkan algoritma non-linear sedangkan statistik bersifat linier (Makridakis et al., 2018). Selain itu jika peramalan bertujuan mengurangi nilai kesalahan, maka pendekatan ML lebih efektif untuk digunakan (Cecaj et al., 2020). Penelitian ini akan menggunakan metode *stacking*, dimana mekanisme yang ada pada *stacking* yakni menggabungkan hasil peramalan beberapa algoritma dasar untuk kemudian hasil ini digunakan oleh algoritma lainnya untuk peramalan lanjutan. *Stacking* telah terbukti memiliki kemampuan melampaui beberapa metode lain (Jiang et al., 2019) (Izonin & Tkachenko, 2021) (Zhai & Chen, 2018).

Secara umum data konsumsi listrik terbagi menjadi empat jenis yakni peramalan jangka panjang, peramalan jangka menengah, peramalan jangka pendek dan peramalan jangka sangat pendek (Zheng et al., 2017). Penelitian tentang konsumsi listrik telah banyak dilakukan, seperti penelitan (Divina et al., 2018) (Shi et al., 2018) (Kuo, 2018)

(Luy et al., 2018). Perbedaan antara penelitian tersebut dengan penelitian ini terakit dua hal yakni metode dan jenis data. Terkait metode, penelitian ini akan menerapkan metode *stacking* menggunakan 4 algoritma yakni RF, SVM, NN dan *Generalized Linier Model* (GLM). Di sisi lain, penelitian-penelitian yang sudah disebutkan sebelumnya menggunakan jenis data multivariate ataupun jika menggunakan data univariate maka hanya menggunakan satu interval data saja. Sedangkan pada penelitian ini akan menggunakan data univariate dengan interval waktu yang berbeda yakni data per 15 menit, data per 30 menit dan data per jam. Penggunaan data univariat didasarkan pada penelitian sebelumnya yang menyatakan bahwa data runtun waktu univariat, akan menunjukkan hasil yang lebih baik ketika menggunakan data dengan interval yang pendek (Sreehari et al., 2021).

Penelitian ini bermaksud untuk meningkatkan akurasi peramalan konsumsi listrik. Secara umum peningkatan akurasi hasil peramalan menjadi hal yang sangat penting, karena penurunan nilai akurasi yang bahkan sangat kecil merupakan keuntungan yang signifikan (Petropoulos & Spiliotis, 2021). Perusahaan kelistrikan di negara mana pun harus siap untuk memenuhi konsumsi di masa depan tanpa mengetahui apa yang akan terjadi sebelumnya. Peramalan konsumsi listrik memainkan peran penting dalam industri listrik, karena memberikan dasar untuk membuat keputusan dalam perencanaan dan pengoperasian sistem perusahaan. Model peramalan yang baik tentang konsumsi listrik sangat penting untuk berfungsinya sistem kelistrikan salah satu alasannya adalah karena biaya listrik merupakan faktor penentu daya saing suatu negara. Penelitian ini berupaya mengusulkan sebuah model *hybrid* dengan memanfaatkan metode *stacking* untuk mengintegrasikan beberapa metode guna meningkatkan akurasi peramalan konsumsi listrik. Selain itu juga bertujuan untuk melihat interval data yang manakah yang akan memberikan akurasi terbaik.

2. Metode Penelitian

Data yang digunakan dalam penelitian ini adalah data konsumsi listrik dengan interval 15 menit, 30 menit dan 1 jam. Data tersebut diperoleh dari <https://www.entsoe.eu> namun hanya mengambil data dari dua negara saja yakni Inggris dan Jerman. Jumlah konsumsi menjadi variabel independen sedangkan waktu dipilih sebagai variabel dependen. Ketiga data dengan interval berbeda tersebut akan diuji stasioner dengan pengujian ADF menggunakan perangkat lunak R. Pada tahap pra proses selanjutnya dilakukan normalisasi data dengan menggunakan *Z-Transformation* karena merupakan metode yang cocok dengan semua data stasioner. Normalisasi data memiliki dampak signifikan pada performa model sehingga kualitas data pun terjamin. Proses normalisasi hingga validasi hasil peramalan akan memanfaatkan perangkat lunak Rapidminer Studio.

Sebagian besar penelitian runtun waktu menghasilkan kesimpulan bahwa menggabungkan beberapa metode akan meningkatkan akurasi dibandingkan hanya menggunakan satu metode saja (Lee et al., 2020). Penelitian yang pernah dilakukan dengan cara penggabungan beberapa metode biasanya dilakukan dengan cara mengubah satu atau beberapa hal yang ada pada metode tersebut contohnya membagi kelompok data sesuai dengan fitur temporal (Cheung et al., 2018), menggabungkan hasil perbandingan beberapa metode guna menghasilkan prediksi akhir dari variabel tujuan (Liapis et al., 2020), mendinamisasikan nilai bobot (Doudkin et al., 2019), memanfaatkan penggabungan beberapa metode *bagging-boosting* (Lee et al., 2020)

(Khwaja et al., 2020) ataupun *stacking* (Divina et al., 2018) (Jiang et al., 2019) (Ma et al., 2018).

Penerapan *stacking* dilakukan dengan membangun model menggunakan beberapa bentuk algoritma yang berbeda di level dasar, kemudian algoritma di level atasnya dilatih untuk membuat peramalan akhir menggunakan peramalan yang dihasilkan oleh algoritma di level dasar. Karena *stacking* digunakan untuk menyusun secara betumpuk beberapa algoritma yang berbeda, maka akan ada dua jenis model, yakni model dasar (model level-0) dan satu model meta (model level-1). Inti dari *stacking* adalah menggunakan model level-1 untuk belajar dari model peramalan yang dihasilkan di level-0. Umumnya, dengan memanfaatkan *stacking* akan memberikan hasil yang lebih akurat dibandingkan dengan model terbaik yang ada pada level-0. Salah satu hal penting lainnya adalah dengan mendapatkan data pelatihan untuk model level-1, dalam hal ini dilakukan *Cross Validation*. Nilai K dalam penelitian ini ditentukan sebesar 10.

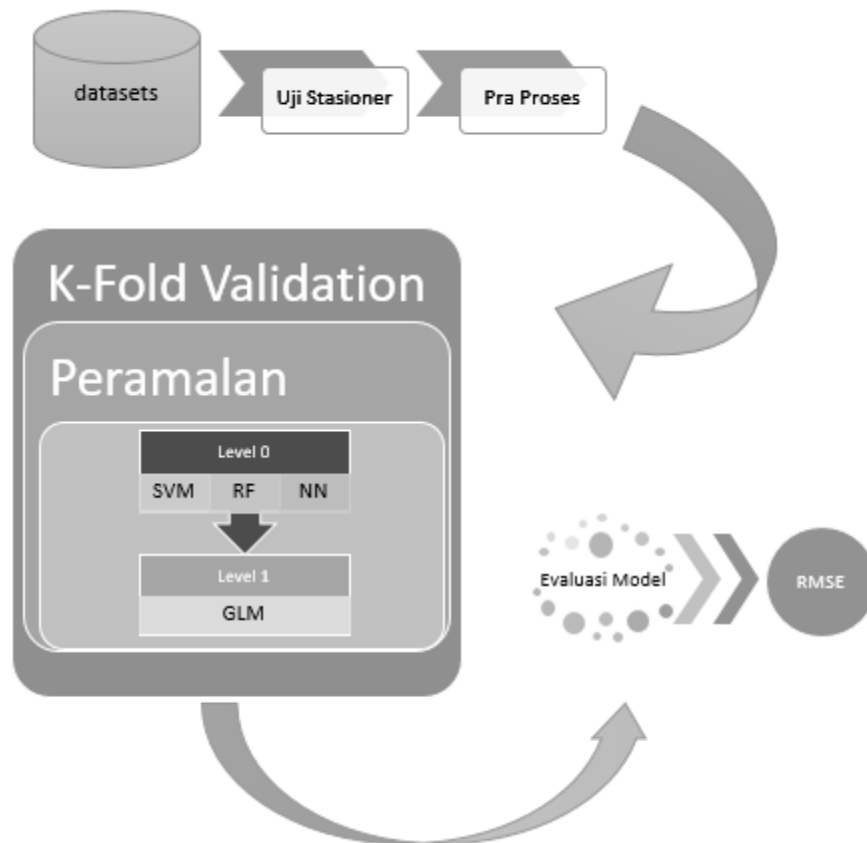
Metode *stacking* dapat dijelaskan dengan suatu kondisi bahwa terdapat satu set N yang terdiri dari beberapa algoritma pembelajaran berbeda L_k , $k = 1, \dots, N$. Terdapat persamaan lain untuk mewakili nilai yang akan direkam yakni x dan y, dimana $x = (X_1, \dots, X_w)$ sedangkan w dan $y = (X_{w+1}, \dots, X_{w+h})$ dimana peramalan bertujuan untuk melihat nilai dari h. Sebagai contoh jika terdapat sebuah model M_{kj} , dimana $k = 1, \dots, N$ dan $j = 1, \dots, h$ merupakan model yang diperoleh dari algoritma pembelajaran L_k pada x untuk memprediksi X_{wj} , serta f_j merupakan fungsi generalisasi yang akan menggabungkan model guna meramal nilai yang ingin dicari. Maka nilai ramalan dari X_{wj} dapat dilihat pada persamaan 1:

$$X_{w+j} = f_j(m_{1j}, \dots, m_{Nj}) \quad (1)$$

Penelitian ini menggunakan *Random Forest* (RF), *Neural Network* (NN) dan *Support Vector Machine* (SVM) di level-0 dan *Generalized Linear Model* (GLM) di level-1. RF adalah metode klasifikasi yang terdiri dari beberapa pohon keputusan yang tidak berkorelasi (Altınçöp & OKTAY, 2018). Semua pohon keputusan tumbuh di bawah jenis pengacakan tertentu selama proses pembelajaran. RF juga dapat digunakan untuk regresi, karenanya dimungkinkan untuk menggunakan RF untuk prediksi deret waktu. Dalam penggunaan *Stacking*, RF telah terbukti memiliki performa yang lebih baik dibandingkan dengan hanya menggunakan RF saja (Varshini et al., 2021). *Support Vector Machine* (SVM) seringkali digunakan sebagai metode klasifikasi seperti RF tetapi dapat juga digunakan untuk regresi, yang berarti keduanya dapat digunakan untuk peramalan deret waktu (Zimmermann & Howlett, 2021). NN merupakan metode yang paling sering digunakan untuk peramalan konsumsi listrik. Mulai dari penggunaan NN sebagai metode tunggal maupun penerapan NN yang dioptimasi oleh metode lainnya (Kapustina et al., 2020) (Leite et al., 2022) (Barić et al., 2019). Mayoritas peramalan yang menerapkan NN memberikan hasil yang signifikan, baik dalam performa maupun rendahnya nilai *error*.

Pada level-1 digunakan GLM, metode ini dapat digunakan sebagai pengganti model regresi linier. GLM sering juga digunakan pada struktur data dengan variabel eksplanatori tetapi juga dapat digunakan untuk peramalan deret waktu (Fleurke, 2017). Perpaduan antara RF dan GLM menjadi salah satu pilihan terbaik karena mampu meningkatkan performa peramalan (Han et al., 2021). Penelitian lainnya telah

menghasilkan performa terbaik untuk meramalkan jumlah konsumsi listrik, namun seringkali yang digunakan adalah data multivariat (Kaytez et al., 2015). Sedangkan pada penelitian ini seperti yang sudah dipaparkan sebelumnya, yang akan digunakan adalah data univariat. Adapun Secara umum proses keseluruhan dari penelitian ini dapat terlihat pada gambar 1.



Gambar 1. Proses Penelitian

3. Hasil dan Pembahasan

3.1. Uji Stasioner

Tahap awal yang dilakukan adalah memeriksa stasioneritas data dengan melakukan uji ADF, yang hasilnya dapat terlihat pada gambar 2. Hipotesis yang diberlakukan adalah:

H0: data runtun waktu belum stasioner

H1: data runtun waktu sudah stasioner

$\alpha = 5\%$

Berdasarkan hasil uji, didapatkan nilai p-value sebesar 0.01 yakni lebih kecil dari 5% maka dapat dikatakan bahwa dataset sudah bersifat stasioner, sehingga data sudah langsung dapat digunakan untuk peramalan runtun waktu.

```

> adf.test(d15)
Augmented Dickey-Fuller Test
data: d15
Dickey-Fuller = -26.807, Lag order = 58, p-value = 0.01
alternative hypothesis: stationary

> adf.test(d30)
Augmented Dickey-Fuller Test
data: d30
Dickey-Fuller = -7.0109, Lag order = 46, p-value = 0.01
alternative hypothesis: stationary

> adf.test(d60)
Augmented Dickey-Fuller Test
data: d60
Dickey-Fuller = -15.31, Lag order = 36, p-value = 0.01
alternative hypothesis: stationary
    
```

Gambar 2. Hasil Uji ADF

3.2. Pra Proses

Tahap pertama dalam Pra Proses yang dilakukan adalah normalisasi dalam hal ini dilakukan dengan menggunakan metode *Z-Transformation*. Normalisasi dengan metode ini menghasilkan nilai baru berdasarkan perbedaan nilai rata-rata dan juga nilai standar deviasi. Adapun sebagian kecil dari data yang belum dan sudah dinormalisasi dapat terlihat pada tabel 1.

Tabel 1. Perbandingan data asli dan data hasil transformasi

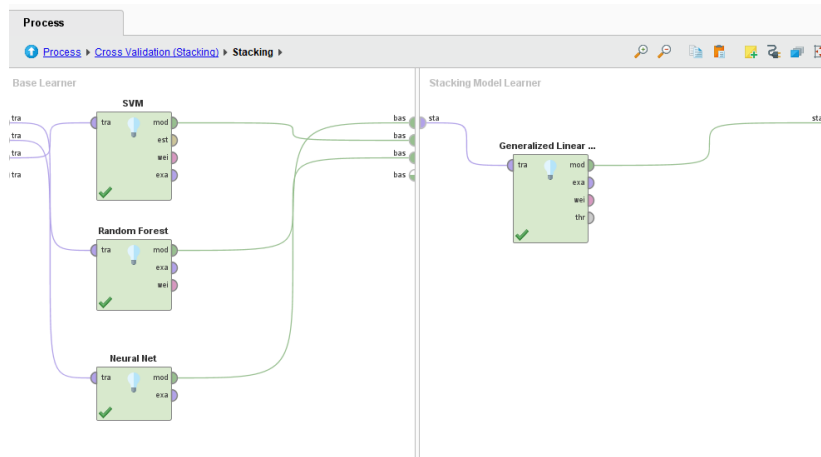
No	Data Asli	Data Hasil Transformasi
1	41517.72	-1.5909746743939028
2	41179.17	-1.6267177838035298
3	40756.4	-1.6713525921482582
4	40617.76	-1.6859897940048543
5	40312.25	-1.7182446377671794
6	39984.39	-1.75285912853971
7	39626.17	-1.7906789384724129
8	39472.35	-1.806918799909095
9	39217.12	-1.8338652297263123
10	38953.62	-1.8616847817258297

Tahap berikutnya dari pra proses adalah sebuah prosedur yang sudah diketahui secara luas bahwasanya saat memproses data univariat runtun waktu, maka akan dilakukan *re-shaping* sehingga data menjadi multivariat. Mekanisme yang dilakukan adalah dengan konsep *windowing*. Pada dataset dengan interval 15 menit dilakukan *windowing* dengan jumlah *window* 4, sedangkan pada dataset dengan interval 30 menit maka *windowing* yang dilakukan adalah dengan jumlah *window* 48, kemudian pada dataset terakhir yang memiliki interval satu jam, maka *windowing* dilakukan dengan jumlah *window* 24.

3.3. Proses Peramalan


Dataset konsumsi listrik yang telah dilakukan pra proses kemudian dibagi menjadi data training dan testing. Pembagian dataset ini akan digunakan dalam

peramalan hingga validasi. Dalam penelitian ini digunakan *K-Fold Validation*, dengan nilai $k=10$. Tampilan penggunaan Rapidminer Studio dapat dilihat pada Gambar 3.



Gambar 3. Arsitektur *Stacking* pada Rapidminer Studio

Tampilan pra-proses data seperti yang telah dijelaskan di bagian 3.2 pada Rapidminer Studio terlihat pada gambar 4.



Gambar 4. ETL pada Rapidminer Studio

4. Hasil dan Pembahasan

Penelitian diawali dengan melakukan peramalan menggunakan tiga algoritma secara tunggal yaitu NN, RF, SVM dan GLM. RMSE yang dihasilkan dari peramalan dengan algoritma tunggal ini dapat terlihat di tabel 2. Berdasarkan tabel tersebut dapat terlihat bahwa pada untuk semua interval NN memberikan hasil RMSE yang lebih rendah. Dengan perbedaan interval data maka dapat terlihat juga perbedaan urutan tingkat error dari algoritmanya. Untuk data dengan interval 15 menit setelah NN diikuti SVM, RF dan GLM. RMSE NN, RF dan SVM memang tidak begitu jauh yakni hanya berbeda sekitar 0.003 hingga 0.006. Namun dari hasil ini dapat disimpulkan bahwa NN sebagai metode yang paling rendah nilai error nya ketika digunakan untuk data interval

sangat pendek. Sedangkan pada data dengan interval 30 menit urutan tingkat error dari terendah hingga tertinggi adalah NN, GLM, SVM dan RF. Kemudian pada data dengan interval 60 menit urutan tingkat errornya yakni NN, RF, SVM dan terakhir adalah GLM.

Berdasarkan hasil tersebut dapat disimpulkan bahwa NN menjadi algoritma yang menghasilkan RMSE terkecil untuk semua interval data. Selain itu data dengan interval 15 menit memberikan nilai RMSE yang lebih kecil daripada interval data lainnya.

Tabel 2. Perbandingan RMSE Algoritma Tunggal

Interval Data	RMSE			
	NN	RF	SVM	GLM
15 menit	0.044	0.048	0.047	0.050
30 menit	0.130	0.168	0.162	0.157
60 menit	0.144	0.157	0.176	0.177

Proses utama dari peramalan di penelitian ini karena menggunakan metode *stacking* maka prosesnya terbagi menjadi dua, yakni di level dasar (level-0) dan di level *stacking* (level-1) seperti terlihat pada gambar 5. Proses di level-0 memanfaatkan tiga algoritma yang sama dengan peramalan tunggal yakni NN, RF dan SVM. Kecuali GLM akan digunakan pada level-1.

Hasil peramalan tersebut menghasilkan RMSE yang terlihat pada tabel 4. Berdasarkan hasil tersebut *stacking* memberikan nilai RMSE terkecil dibandingkan dengan penggunaan algoritma tunggal. Interval data yang menghasilkan RMSE terkecil adalah interval 15 menit. Berdasarkan hasil tersebut dapat dikatakan bahwa interval data terkecil memberikan nilai RMSE yang lebih baik serta *stacking* memberikan performa yang lebih baik daripada penggunaan algoritma tunggal.

Tabel 3. Perbandingan RMSE Stacking

Interval Data	RMSE Stacking
15 menit	0.037
30 menit	0.113
60 menit	0.115

4. Kesimpulan

Berdasarkan hasil peramalan yang telah dilakukan, pemanfaatan *stacking* terbukti dapat memberikan nilai *error* yang lebih kecil dibandingkan menggunakan algoritma tunggal dengan perbedaan sekitar 0,7%. Sedangkan interval data terbaik dengan nilai *error* yang paling kecil adalah interval data konsumsi listrik per 15 menit yakni dengan perbedaan *error* senilai 7% dibandingkan dengan interval 30 menit maupun 60 menit. Sedangkan penggunaan interval data 30 dan 60 menit tidak memberikan perbedaan *error* yang cukup signifikan.

Daftar Pustaka

- Ahmad, T., & Chen, H. (2020). A review on machine learning forecasting growth trends and their real-time applications in different energy systems. *Sustainable Cities and Society*, 54, 102010. <https://doi.org/10.1016/j.scs.2019.102010>
- Altınçöp, H., & OKTAY, A. B. (2018). Air Pollution Forecasting with Random Forest Time Series Analysis. *International Conference on Artificial Intelligence and Data Processing (IDAP)*, 8–12. <https://doi.org/10.1109/IDAP.2018.8620768>
- Barić, I., Grbić, R., & Nyarko, E. K. (2019). Short-Term Forecasting of Electricity Consumption Using Artificial Neural Networks - an Overview. *2019 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, 1076–1081.
- Cecaj, A., Lippi, M., Mamei, M., & Zambonelli, F. (2020). Comparing deep learning and statistical methods in forecasting crowd distribution from aggregated mobile phone data. *Applied Sciences (Switzerland)*, 10(18). <https://doi.org/10.3390/APP10186580>
- Chayama, M., & Hirata, Y. (2016). When univariate model-free time series prediction is better than multivariate. *Physics Letters A*, 1, 1–7. <https://doi.org/10.1016/j.physleta.2016.05.027>
- Cheung, C. M., Kannan, R., & Prasanna, V. K. (2018). Temporal Ensemble Learning of Univariate Methods for Short Term Load Forecasting. *2018 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)*.
- Chuentawat, R., & Kan-ngan, Y. (2018). The Comparison of PM2.5 forecasting methods in the form of multivariate and univariate time series based on Support Vector Machine and Genetic Algorithm. *2018 15th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, 572–575.
- Divina, F., Gilson, A., Vela, F. G., Torres, M. G., & Torres, J. F. (2018). Stacking Ensemble Learning for Short-Term Electricity Consumption Forecasting. *Energies*, 11(4), 1–31. <https://doi.org/10.3390/en11040949>
- Doudkin, A., Marushko, Y., Owsinski, J., & Pawlowski, T. (2019). Spacecraft Telemetry Time Series Forecasting with Ensembles of Neural Networks. *Proceedings of the 2019 10th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications*,

- IDAACS 2019, 2(3), 752–756. <https://doi.org/10.1109/IDAACS.2019.8924252>
- Fleurke, S. (2017). *Forecasting Automobile Sales using an Ensemble of Methods*. 16, 329–337.
- Han, S., Williamson, B. D., & Fong, Y. (2021). Improving random forest predictions in small datasets from two - phase sampling designs. *BMC Medical Informatics and Decision Making*, 3, 1–9. <https://doi.org/10.1186/s12911-021-01688-3>
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting : Principles and Practice*.
- Izonin, I., & Tkachenko, R. (2021). *Stacking-based GRNN-SGTM Ensemble Model for Prediction Tasks*. 326–330.
- Jiang, M., Liu, J., & Zhang, L. (2019). An improved Stacking framework for stock index prediction by leveraging tree-based ensemble models and deep learning algorithms. *Physica A*, 122272. <https://doi.org/10.1016/j.physa.2019.122272>
- Kapustina, E., Shutov, E., Barskaya, A., & Kalganova, A. (2020). *Predicting Electric Energy Consumption for a Jerky Enterprise*. 396–406. <https://doi.org/10.4236/epe.2020.126024>
- Kaytez, F., Taplamacioglu, M. C., Cam, E., & Hardalac, F. (2015). Electrical Power and Energy Systems Forecasting electricity consumption : A comparison of regression analysis , neural networks and least squares support vector machines. *International Journal of Electrical Power and Energy Systems*, 67, 431–438. <https://doi.org/10.1016/j.ijepes.2014.12.036>
- Khwaja, A. S., Anpalagan, A., Naeem, M., & Venkatesh, B. (2020). Joint bagged-boosted artificial neural networks: Using ensemble machine learning to improve short-term electricity load forecasting. *Electric Power Systems Research*, 179(October 2019), 106080. <https://doi.org/10.1016/j.epsr.2019.106080>
- Kuo, P. (2018). *A High Precision Artificial Neural Networks Model for Short-Term Energy Load Forecasting*. 1–13. <https://doi.org/10.3390/en11010213>
- Lee, S., KC, B., & Choeh, J. Y. (2020). Comparing performance of ensemble methods in predicting movie box office revenue. *Heliyon*, 6(6). <https://doi.org/10.1016/j.heliyon.2020.e04260>
- Leite, F., Costa, K., Rodrigues, P. C., & López-gonzales, J. L. (2022). *Statistical and Artificial Neural Networks Models for Electricity Consumption Forecasting in the Brazilian Industrial Sector*. 1–12.
- Liapis, C. M., Karanikola, A., & Kotsiantis, S. (2020). An ensemble forecasting method using univariate time series COVID-19 data. *ACM International Conference Proceeding Series*, 50–52. <https://doi.org/10.1145/3437120.3437273>
- Luy, M., Ates, V., Barisci, N., Polat, H., & Cam, E. (2018). Short-Term Fuzzy Load Forecasting Model Using Genetic–Fuzzy and Ant Colony–Fuzzy Knowledge Base Optimization. *Applied Sciences*, 8(6). <https://doi.org/10.3390/app8060864>
- Ma, Z., Wang, P., Gao, Z., Wang, R., & Khalighi, K. (2018). Ensemble of machine learning algorithms using the stacked generalization approach to estimate the warfarin dose. *PLOS ONE*.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE*, 13(3), 1–26. <https://doi.org/10.1371/journal.pone.0194889>
- Naim, I., & Mahara, T. (2018). *Comparative Analysis of Univariate Forecasting Techniques for Industrial Natural Gas Consumption*. May. <https://doi.org/10.5815/ijigsp.2018.05.04>
- Petropoulos, F., & Spiliotis, E. (2021). The Wisdom of the Data : Getting the Most Out

- of Univariate Time Series Forecasting. *Forecasting*, 3, 478–497.
- Petropoulos, F., Wang, X., & Disney, S. M. (2018). The inventory performance of forecasting methods: Evidence from the M3 competition data. *International Journal of Forecasting*. <https://doi.org/10.1016/j.ijforecast.2018.01.004>
- Phan, T. (2018). *Comparative Study on Univariate Forecasting Methods for Meteorological Time Series*. 2380–2384.
- Shi, H., Xu, M., & Li, R. (2018). Deep Learning for Household Load Forecasting — A Novel Pooling Deep RNN. *IEEE Transactions on Smart Grid*, 9(5), 5271–5280. <https://doi.org/10.1109/TSG.2017.2686012>
- Sreehari, K., Adham, M., Cheriya, T. D., & Sheik, R. (2021). A Comparative Study between Univariate and Multivariate Time Series Models for COVID-19 Forecasting. *International Conference on Computational Performance Evaluation (ComPE)*, 485–491.
- Syamsiah, N. O. (2020). *PERAMALAN HARGA TELUR AYAM RAS DI JAKARTA TIMUR*. 5(1).
- Varshini, A. G. P., Kumari, A. K., & Varadarajan, V. (2021). Estimating Software Development Efforts Using a Random Forest-Based Stacked Ensemble Approach. *Electronics*, 10, 1–21.
- Zhai, B., & Chen, J. (2018). Science of the Total Environment Development of a stacked ensemble model for forecasting and analyzing daily average PM 2 . 5 concentrations in Beijing , China. *Science of the Total Environment*, 635, 644–658. <https://doi.org/10.1016/j.scitotenv.2018.04.040>
- Zheng, J., Xu, C., Zhang, Z., & Li, X. (2017). *Electric Load Forecasting in Smart Grids Using Long-Short-Term-Memory based Recurrent Neural Network*. 1–6.
- Zimmermann, A., & Howlett, R. J. (2021). *Human Centred Intelligent Systems*.