

Algoritma *Exponential Smoothing* Untuk Memprediksi Parameter Penyebab Kebakaran Hutan

1st Agustio
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

kuylah@student.telkomuniversity.ac.id

2nd Casi Setianingsih
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

setiacasie@telkomuniversity.ac.id

3rd Ashri Dinimaharawati
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

ashridini@telkomuniversity.ac.id

Abstrak — Kebakaran hutan adalah salah satu bencana alam yang sering terjadi dan membawa dampak buruk bagi lingkungan dan masyarakat sekitar. Pemahaman faktor-faktor penyebab serta prediksi kejadian kebakaran hutan dapat membantu dalam pencegahan dan penanganan dini. Penelitian ini mengembangkan model prediksi parameter penyebab kebakaran hutan menggunakan algoritma *Exponential Smoothing*. Data *time series* yang diambil dari BMKG (Badan Meteorologi dan Geofisika) diolah untuk mendapatkan model yang akurat. Diharapkan dengan adanya model ini, pihak berwenang dapat lebih proaktif dalam mengatasi dan mencegah kebakaran hutan di masa mendatang.

Penelitian ini bertujuan mengembangkan model prediksi penyebab kebakaran hutan berdasarkan parameter seperti suhu, kelembaban, kecepatan angin, dan curah hujan. Memahami parameter ini penting bagi pihak berwenang untuk intervensi dini, mengingat dampak kebakaran terhadap lingkungan dan masyarakat. Melalui *Exponential Smoothing*, studi ini menawarkan solusi teknis untuk prediksi dan pencegahan kebakaran.

Model pembelajaran mesin, dengan nilai R^2 di atas 0,50 dan MAE serta RMSE di bawah 0,2, menunjukkan keefektifannya dalam skenario ini. Model akan diterapkan di sebuah situs web untuk memastikan keterjangkauan bagi semua orang, berfungsi sebagai alat bermanfaat untuk memprediksi dan mengurangi risiko kebakaran hutan di Indonesia.

Kata kunci— Kebakaran hutan, *Exponential Smoothing*, BMKG (Badan Meteorologi dan Geofisika), Model Pembelajaran Mesin

I. PENDAHULUAN

Indonesia dikenal memiliki hutan tropis terbesar kedua di dunia, sering disebut sebagai "paru-paru dunia". Sebagai negara dengan produksi oksigen terbesar kedua dan kemampuan menyimpan karbon yang signifikan, luasnya hutan mempengaruhi risiko kebakaran hutan yang meningkat. Ada dua penyebab utama kebakaran hutan: aktivitas manusia dan alam. Sebagian besar kebakaran terjadi akibat tindakan manusia, terutama saat membuka lahan baru[1].

Kebakaran memiliki dampak negatif tidak hanya bagi manusia, tetapi juga lingkungan[2]. Asap yang dihasilkan

oleh kebakaran hutan kaya akan partikel karbon yang berbahaya bagi kesehatan manusia. Karena massa partikel karbon lebih besar daripada udara, hal ini bisa menyebabkan gejala kesehatan seperti batuk hingga sesak napas. Kepadatan asap yang tebal juga bisa mengurangi visibilitas.

Secara esensial, data *time series* adalah observasi dari suatu proses sepanjang periode waktu tertentu[3]. Data ini digunakan untuk memprediksi kemungkinan kebakaran dengan algoritma *exponential smoothing* dan untuk mengklasifikasikan intensitasnya melalui Fire Weather Index.

II. KAJIAN TEORI

Dalam upaya memahami dan memprediksi fenomena tertentu, seringkali diperlukan pemahaman mendalam tentang konsep-konsep dasar yang melandasi fenomena tersebut. Data *time series* merupakan salah satu instrumen analisis yang memungkinkan para peneliti untuk memeriksa dan memprediksi tren sepanjang waktu. Dengan menggabungkan pemahaman tentang data *time series* dengan algoritma *Exponential Smoothing*, kita dapat menciptakan prediksi yang lebih akurat dan adaptif terhadap perubahan. Selanjutnya, untuk memahami dan menilai risiko kebakaran, *Fire Weather Index* dijadikan sebagai standar dalam mengevaluasi potensi bahaya berdasarkan parameter cuaca dan kondisi lingkungan[3].

Berdasarkan informasi dari BMKG, berbagai faktor iklim memiliki kontribusi signifikan terhadap peningkatan risiko kebakaran hutan. Kenaikan suhu dapat memicu kekeringan, yang pada gilirannya meningkatkan peluang terbakarnya hutan. Udara dengan kelembaban rendah menciptakan lingkungan yang kering, memudahkan bahan bakar alami di hutan untuk terbakar. Di sisi lain, angin yang berhembus kencang bisa memperluas jangkauan api dengan cepat serta memindahkan percikan api ke kawasan yang masih aman. Sementara itu, penurunan curah hujan atau musim kemarau yang berkepanjangan menambah risiko, mengingat fungsi penting hujan dalam menjaga kelembaban hutan.

A. Exponential Smoothing

Teknik Exponential Smoothing merupakan metode yang sering digunakan dalam analisis rangkaian waktu, khususnya saat data menunjukkan adanya tren atau sifat musiman. Inti dari pendekatan ini adalah memberikan penimbangan pada data, dengan observasi terkini mendapatkan penimbangan paling tinggi dan penimbangan untuk data historis berkurang dengan pola eksponensial. Dengan demikian, pendekatan ini bertujuan untuk "menghaluskan" ketidakstabilan dalam data dengan memfokuskan lebih banyak pada informasi terbaru. Elemen sentral dalam Exponential Smoothing adalah koefisien pemulusan (α), yang merupakan angka di antara 0 dan 1, yang menunjukkan seberapa signifikan penimbangan diberikan kepada data terbaru dibandingkan dengan rata-rata data historis[3]. Fleksibilitas metode ini dalam merespons perubahan dalam data menjadikannya pilihan yang tepat untuk situasi di mana ada variasi dalam data atau ketika perubahan mendadak harus diakomodasi dalam proyeksi. Adapun beberapa jenis dari exponential smoothing sebagai berikut:

1. Single Exponential Smoothing

Jenis ini paling cocok untuk data yang stabil tanpa adanya tren atau pola musiman yang jelas. Dalam SES, hanya ada satu koefisien pemulusan (α), yang digunakan. Fokus utama dari pendekatan ini adalah pada data terbaru, dengan asumsi bahwa apa yang terjadi di masa lalu akan terus berlanjut tanpa perubahan signifikan.

2. Double Exponential Smoothing

Double Exponential Smoothing dirancang khusus untuk data yang menunjukkan adanya tren. Di sini, selain koefisien pemulusan untuk data (α), ada koefisien pemulusan tambahan untuk tren β . Pendekatan ini tidak hanya mempertimbangkan data terbaru tetapi juga perubahan atau tren yang mungkin terjadi dalam data tersebut

3. Triple Exponential Smoothing

Juga dikenal sebagai metode Holt-Winters pilihan terbaik untuk data yang memiliki baik tren maupun sifat musiman. Selain (α) untuk data dan (β) untuk tren, ada koefisien pemulusan ketiga (γ), untuk musim. Ini memastikan bahwa metode ini dapat mengakomodasi fluktuasi musiman dalam data sambil tetap mempertimbangkan tren dan data terbaru.

Dalam Penelitian kali ini menggunakan *Triple Exponential Smoothing* karena menghasilkan nilai error yang lebih kecil. *Holt-Winter Exponential Smoothing* mempunyai kelebihan memprediksi data yang memiliki pola tren dan musiman[4]. Karena jenis ini adalah gabungan dari *single* dan *double Exponential Smoothing*. Berikut merupakan rumus perhitungan yang digunakan dalam menggunakan algoritma *Holt-Winter Exponential Smoothing*

$$F_t = F_{t-1} + \alpha(A_{t-1} - F_{t-1}) \quad (1)$$

Holt-Winter Exponential Smoothing memiliki tahap yaitu melakukan observasi terhadap pola tren, level, dan musiman[5].

4. Nilai Level Awal

Nilai level awal ini adalah rata-rata dari n observasi pertama

$$L_t = \frac{(y_1 + y_2 + \dots + y_n)}{n} \quad (2)$$

5. Nilai Tren Awal

Nilai tren awal ini adalah rata-rata diferensiasi dari perbedaan n observasi pertama

$$L_t = \frac{(y_1 + y_2 + \dots + y_n)}{n} \quad (3)$$

6. Nilai Musiman Awal

Nilai musiman awal terdapat dua rumus yang digunakan, yaitu tergantung observasi awal menggunakan *additive* atau *multiplicative*. Jika menggunakan *additive* menggunakan selisih dari nilai y ke- n dengan nilai level. Sedangkan untuk metode *multiplicative* nilai y ke- n dibagi dengan nilai level

$$S_p = Y_p - L_t \quad (4)$$

$$S_p = \frac{Y_p}{L_t} \quad (5)$$

Model Triple Exponential Smoothing (Holt-Winters) dapat didefinisikan dalam tiga jenis dasar berdasarkan bagaimana komponen (level, tren, dan musiman) digabungkan: additive, multiplicative, dan none[6]

a. Komponen Additive

Dalam model additive, komponen tren dan musiman ditambahkan ke komponen level

i. Level Smoothing Alpha (α)

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (6)$$

ii. Seasonal Smoothing Beta (β)

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}(L_{t-1} + b_{t-1}) \quad (5)$$

iii. Seasonal Smoothing Gamma (γ)

$$S_t = \gamma(y_t - L_t) + (1 - \gamma)S_{t-s} \quad (5)$$

7. Komponen Multiplicative

Dalam model multiplicative, komponen tren dan musiman dikalikan dengan komponen level.

i. Level Smoothing Alpha (α)

$$L_t = \alpha\left(\frac{y_t}{S_{t-s}}\right) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (6)$$

ii. Seasonal Smoothing Beta (β)

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}(L_{t-1} + b_{t-1}) \quad (7)$$

iii. Seasonal Smoothing Gamma (γ)

$$S_t = \gamma\left(\frac{y_t}{L_t}\right) + (1 - \gamma)S_{t-s} \quad (8)$$

8. None

Dalam model None , tidak digunakan nilai smoothing dari masing-masing komponen. Langsung dilakukan prediksi dengan menggunakan rumus

$$F_t = \alpha \times Y_t + (1 - \alpha)F_{t-1} \quad (9)$$

C. Fire Weather Index


Sistem Indeks Cuaca Kebakaran (FWI) adalah metode yang diciptakan di Kanada untuk mengevaluasi potensi kebakaran hutan berdasarkan sejumlah elemen iklim dan cuaca. Sistem FWI adalah komponen dari Sistem Penilaian Bahaya Kebakaran Hutan Kanada (CFFDRS). Alat ini dimanfaatkan oleh para pemimpin dan pembuat keputusan untuk mengukur risiko kebakaran hutan dan membantu dalam pengambilan keputusan operasional mengenai pengelolaan kebakaran.

TABEL 1
KATEGORI FIRE WEATHER INDEX

Category	FWI
Low	<1
Moderate	1-6
High	6-13
Very High	>13


III. METODE

A. Diagram Blok Rancangan Sistem Prediksi



GAMBAR 1
Diagram Blok Rancangan Sistem Prediksi

Tahapan metode ada lima seperti gambar diatas. Diawali dengan mengumpulkan datasets sesuai dengan parameter - parameter yang digunakan pada aplikasi ini. Setelah data set dikumpulkan maka dapat dilakukan proses prediksi maupun forecasting. Kemudian perlu dilakukan inisialisasi nilai Level, Trend, dan Seasonal. Ketiga nilai tersebut diperlukan untuk proses perhitungan selanjutnya agar mendapatkan nilai prediksi maupun forecast. Selanjutnya menentukan nilai alpha (α), beta (β), dan gamma (γ). Ketiga nilai tersebut juga dikenal Smoothing Level (α), Smoothing Trend (β), dan Smoothing Seasonal (γ). Apabila telah mendapatkan nilai tersebut dapat dilanjutkan untuk menghitung Forecasting. Forecasting membutuhkan nilai - nilai tersebut, jika nilai tersebut tidak ada maka tidak dapat dilakukan forecasting[7]. Terakhir dapat diuji tingkat persentase error rata - rata dari hasil forecasting



GAMBAR 2

Skematik Model Prediksi Parameter Kebakaran hutan

1. Inisialisasi

Holt-Winters Exponential Smoothing (HWES) adalah teknik prediksi yang umumnya digunakan untuk data deret waktu dengan unsur tren dan musiman. Metode ini memperluas konsep pemulusan eksponensial dasar dan ganda (metode Holt)[7].

Ada tiga elemen utama dalam HWES:

- Level: Rata-rata data.
- Trend: Perubahan data seiring waktu.
- Seasonal: Pola berulang dalam jangka waktu tertentu.

Ketika menyiapkan model HWES, ada beberapa parameter untuk diatur:

- Alpha (α): Parameter yang menghaluskan level. Nilainya antara 0 dan 1. Semakin mendekati 1, semakin cepat model merespons perubahan data.
- Beta (β): Parameter yang menghaluskan tren. Juga antara 0 dan 1. Semakin mendekati 1, semakin cepat respons tren terhadap perubahan.
- Gamma (γ): Parameter untuk menghaluskan musiman. Antara 0 dan 1. Semakin mendekati 1, semakin cepat komponen musiman merespons.
- L0, T0, S0: Nilai awal untuk Level, Trend, dan Seasonal. Biasanya diambil dari beberapa data awal tetapi ada metode lain yang lebih maju.
- Frekuensi Musiman: Jumlah periode dalam siklus musiman. Misalnya, untuk data bulanan dengan pola tahunan, nilainya 12.
- Model Aditif atau Multiplikatif: Cara menggabungkan musiman dengan level dan tren, apakah dengan penjumlahan atau perkalian.

Dalam konfigurasi, Anda perlu memilih model musiman (aditif atau multiplikatif), menentukan frekuensinya, dan mungkin memberikan nilai awal untuk α , β , dan γ [9]. Tetapi di banyak perangkat lunak, parameter ini bisa diatur secara otomatis. Selalu baik untuk menguji model pada data baru untuk memastikan akurasi prediksi.

2. Training Dataset

Pada tahapan ini, program akan melakukan pelatihan data yang diberikan dan akan berguna untuk model *exponential smoothing* dapat mempelajari pola dan struktur data yang memiliki *trend* dan *seasonal* pada data yang bertipe *time-series*. Kemudian data uji merupakan data untuk menguji performa dari model *exponential smoothing*

3. Prediksi

Tahap ini berisi kode yang dimana program akan menggunakan model *exponential smoothing* yang telah

tersedia dan telah disesuaikan untuk memprediksi data. Pada bagian ini, terdapat pembuatan variabel baru untuk nilai dari hasil prediksi. Prediksi yang dilakukan memiliki jumlah periode sama dengan data uji (data test) yang kemudian akan menghasilkan output untuk digunakan dalam standarisasi dengan metode z-score dan juga akan digunakan untuk diubah bentuknya ke dalam array.

B. Data Time Series

Time series adalah sekumpulan data yang dikumpulkan atau direkam pada interval waktu yang berurutan. Dalam konteks BMKG (Badan Meteorologi, Klimatologi, dan Geofisika) di Indonesia, data *time series* umumnya terkait dengan pengamatan dan pencatatan kondisi cuaca, iklim, dan fenomena geofisika lainnya

Berikut contoh sample data Kotawaringin Barat dari tahun 2019 yang diambil dari BMKG empat parameter yang digunakan yaitu suhu, kelembaban, curah hujan, dan kecepatan angin yang digunakan untuk sebagai data training

	Date	Temperature	Humidity	Rainfall	Wind
0	01-01-2019	32.0	88.0	3.5	5.0
1	02-01-2019	32.0	93.0	3.5	4.0
2	03-01-2019	33.0	95.0	3.5	5.0
3	04-01-2019	33.2	84.0	13.5	4.0
4	05-01-2019	32.4	87.0	13.5	4.0
5	06-01-2019	32.8	84.0	13.5	4.0
6	07-01-2019	32.6	90.0	13.5	5.0

GAMBAR 3
Sample Data Set Kotawaringin Barat

C. Evaluasi Peforma Model

Tahap akhir adalah proses perhitungan nilai error dengan membandingkan hasil dari prediksi dan juga data uji (data test) yang telah distandarisasi dengan metode Z-Score. Metode Z-Score merupakan teknik statistik yang digunakan untuk mengubah data menjadi skor Z atau nilai standar. Metode ini memungkinkan untuk membandingkan data dan memahami posisi relatif pada setiap data dalam distribusinya. Berikut adalah persamaan rumus untuk menghitung skor Z.

$$Z = \left(\frac{X - \mu}{\sigma} \right) \quad (10)$$

Berdasarkan dari hasil standarisasi metode Z-Score maka pada bagian ini dilakukan evaluasi agar dapat mengetahui performa dari model algoritma *exponential smoothing* yang telah diterapkan [8].

1. MAE (Mean Abosolute Error)

MAE bisa digunakan saat outlier dianggap sebagai kesalahan dalam data. MAE, dengan sifatnya yang didasarkan pada norma L1, tidak memberikan sanksi keras kepada outlier saat pelatihan, sehingga memberikan ukuran efektivitas model yang cukup umum dan tidak spesifik. Namun, jika data uji juga penuh dengan outlier, maka evaluasi model mungkin tidak akan menonjol. Sebuah MAE yang mendekati 0

menunjukkan performa yang bagus. Sebaliknya, MAE yang jauh dari 0 menunjukkan performa yang kurang memuaskan.

2. RMSE (Root Mean Absolute Error)

RMSE (Root Mean Square Error) merupakan metrik populer yang digunakan untuk menilai ketepatan model prediksi, khususnya dalam bidang regresi. Metrik ini mengukur seberapa besar kesalahan yang dihasilkan model dalam unit yang sama dengan variabel yang kita coba prediksi.

3. R-Square

R-square dikenal sebagai koefisien determinasi, mengukur seberapa efektif variabel independen dalam suatu model regresi dalam memprediksi variabel dependen. Ini mengkalkulasi sejauh mana variabilitas dari variabel dependen yang dijelaskan oleh model dibandingkan dengan variabilitas totalnya


D. Fire Weather Index

Fire Weather Index adalah salah satu sistem yang digunakan untuk menilai risiko kebakaran hutan berdasarkan kondisi cuaca dan faktor-faktor lingkungan lainnya. Dengan kata lain, FWI memberikan skor numerik yang mencerminkan seberapa besar potensi suatu area untuk mengalami kebakaran hutan berdasarkan data yang dikumpulkan.

IV. HASIL DAN PEMBAHASAN

Beragam-macam metrik statistik, termasuk mean absolute error (MAE), root mean squared error (RMSE), dan r-square, diaplikasikan untuk mengukur kinerja metode pemulusan eksponensial. Dari hasil studi kami, tampak bahwa model Pemulusan Eksponensial sukses memberikan prediksi yang akurat terkait terjadinya kebakaran hutan. Meski begitu, penting sekali untuk selalu mengaktualisasi model dengan data terbaru agar dapat meningkatkan keakuratan prediksinya.


A. Suhu



GAMBAR 4
Hasil Prediksi Parameter Suhu

Pada gambar diatas merupakan hasil grafik pengujian prediksi dan forecast pada data temperature. Berdasarkan pada gambar tersebut dapat terlihat perbandingan yang dilakukan setelah melakukan training pada dataset melakukan 30 hari predict serta forecast


B. Kelembaban



GAMBAR 5
Hasil Prediksi Parameter Kelembaban

Pada gambar diatas merupakan hasil grafik pengujian prediksi dan forecast pada data humidity atau kelembaban. Berdasarkan pada gambar tersebut dapat terlihat perbandingan yang dilakukan setelah melakukan training pada dataset melakukan 30 hari predict serta forecast


C. Kecepatan Angin



GAMBAR 6
Hasil Prediksi Parameter Kecepatan Angin

merupakan hasil grafik pengujian prediksi dan forecast pada data *wind* atau kecepatan angin. Berdasarkan pada gambar tersebut dapat terlihat perbandingan yang dilakukan setelah melakukan *training* pada *dataset* melakukan 30 hari *predict* serta *forecast*.


D. Curah Hujan



GAMBAR 7
Hasil Prediksi Curah Hujan

merupakan hasil grafik pengujian prediksi dan forecast pada data *rainfall* atau curah hujan. Berdasarkan pada gambar tersebut dapat terlihat perbandingan yang dilakukan setelah melakukan *training* pada *dataset* melakukan 30 hari *predict* serta *forecast*

E. Evaluasi Parameter



GAMBAR 8
Evaluasi Prediksi Parameter Kebakaran Hutan

Hasil penilaian untuk semua parameter yang diperkirakan di West Kotawaringin sungguh memberikan harapan, dengan menampilkan performa yang sangat baik. Sebuah nilai R-squared yang menakjubkan yaitu 0,93 serta Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE) berturut-turut 0,024 dan 0,057 untuk estimasi suhu menandakan bahwa model ini mampu menggambarkan hampir 93% perbedaan suhu. Dengan MAE sebesar 0,037, RMSE 0,089, dan R-squared yang tinggi sekitar 0,82, estimasi angin juga menunjukkan ketepatan yang menonjol, yang artinya model ini mampu mencakup sekitar 82% perbedaan angin. Model ini menunjukkan performa cemerlang dalam mengestimasi kelembaban, mencakup 92% perbedaan dengan R-squared 0,92, RMSE 0,074, dan MAE 0,055. Selain itu, prediksi curah hujan juga memperlihatkan ketepatan yang memukau, dengan MAE 0,026, RMSE 0,033, dan R-squared fenomenal sebesar 0,98, yang berarti model mampu menjelaskan lebih dari 98% perbedaan dalam curah hujan. Kemampuan model dalam menggambarkan persentase perbedaan yang sangat tinggi pada parameter-parameter tersebut menunjukkan keefektifan dan kepercayaannya.

V. KESIMPULAN

Berdasarkan evaluasi prediksi parameter kebakaran hutan di West Kotawaringin melalui teknik pemulusan eksponensial, model yang dihasilkan menunjukkan kinerja yang mengesankan. Parameter seperti suhu, kelembaban, kecepatan angin, dan curah hujan telah diprediksi dengan akurasi yang menonjol, sebagaimana ditunjukkan oleh nilai R-squared dan metrik evaluasi lainnya. Lebih lanjut, model berhasil merepresentasikan antara 82% hingga 98% dari variasi masing-masing parameter. Ini menunjukkan keandalan dan efisiensi dari metode pemulusan eksponensial dalam menilai faktor-faktor krusial yang mempengaruhi potensi kebakaran hutan.

REFERENSI

- [1] R. Kumalawati, D. Anjarini, and Elisabeth, "Penyebab kebakaran hutan dan lahan gambut di kabupaten barito kuala provinsi kalimantan selatan," Prosiding Seminar Nasional diselenggarakan Pendidikan Geografi FKIP UMP, 2019
- [2] Aminah, C. Y. Krah, Perdinan, and Perdinan, "Forest fires and management efforts in Indonesia (a review),"

in *IOP Conference Series: Earth and Environmental Science*, 2020. doi: 10.1088/1755-1315/504/1/012013.

- [3] S. Smyl, "A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting," *Int J Forecast*, vol. 36, no. 1, 2020, doi: 10.1016/j.ijforecast.2019.03.017.
- [4] Liu, Z., Zhu, Z., Gao, J., & Xu, C. (2021). Forecast Methods for Time Series Data: A Survey. *IEEE Access*, 9. <https://doi.org/10.1109/ACCESS.2021.3091162>
- [5] Kumar Pradeep, Rahul, & Ravindharaan. (2021). Early Forest Fire Detection Using Machine Learning Algorithms. *International Journal of New Technology and Research*, 7(4), 1–5
- [6] Ma, W., Feng, Z., Cheng, Z., Chen, S., & Wang, F. (2020). Identifying forest fire driving factors and related impacts in China using random forest algorithms. *Forests*, 11(5). <https://doi.org/10.3390/F11050507>
- [7] Sari, E. N., Susanto, B., & Setiawan, A. (2021). Perbandingan Hasil Peramalan Jumlah Wisatawan Mancanegara dengan Metode Box-Jenkins dan Exponential Smoothing. *Jambura Journal of Probability and Statistics*, 2(1)
- [8] Renner, G., Nellessen, A., Schwiers, A., Wenzel, M., Schmidt, T. C., & Schram, J. (2019). Data preprocessing & evaluation used in the microplastics identification process: A critical review & practical guide. In *TrAC - Trends in Analytical Chemistry* (Vol. 111). <https://doi.org/10.1016/j.trac.2018.12.00>
- [9] Smyl, S. (2020). A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, 36(1), 75–85. <https://doi.org/10.1016/j.ijforecast.2019.03.017>