

Komparasi *Moving Average*, *Exponential Smoothing* Dan *Naive Model* Dalam Peramalan Produksi Sereal di Indonesia

Thabed Tholib Baladraf¹, Hifdzil Adila²

¹Program Studi Teknik Industri Pertanian, Fakultas Teknologi Pertanian, IPB University
²Program Studi Teknologi Industri Pertanian, Fakultas Teknologi Pertanian, Universitas Jember
e-mail: ¹thabedtholib@apps.ipb.ac.id,
e-mail: ²hifdziladila@gmail.com

Diterima	Direvisi	Disetujui
01-02-2026	06-04-2026	11-05-2026

Abstrak - Sereal merupakan kebutuhan pangan utama bagi masyarakat Asia Tenggara, terkhusus Indonesia. Hal ini menjadikan sereal sebagai parameter ketahanan pangan suatu negara sehingga penting untuk dilakukan peramalan terhadap jumlah produksi sereal guna membantu perencanaan yang lebih efektif dalam memenuhi kebutuhan pangan masyarakat Indonesia. Tujuan dari penelitian ini yaitu untuk membandingkan metode terbaik dalam meramalkan produksi sereal di Indonesia dengan menggunakan metode *Moving Average*, *Exponential Smoothing*, dan *Naive Model*. Metode penelitian menggunakan data sekunder dari World Bank dan United Nations Food and Agriculture Organization (FAO) mengenai produksi sereal Indonesia pada tahun 1961-2020 dan melakukan peramalan dengan ketiga metode tersebut menggunakan parameter validasi MAD dan MAPE. Hasil penelitian menunjukkan bahwa *Moving Average* dengan periode 2 merupakan metode terbaik dengan nilai MAD sebesar 1.082.453 ton dan MAPE sebesar 2,59%, jauh lebih akurat dibandingkan *Exponential Smoothing* (MAPE 5,20%) dan *Naive Model* (MAPE 10,81%). Produksi sereal untuk 10 tahun kedepan (2021-2030) juga diproyeksikan menunjukkan pertumbuhan konsisten dengan prediksi mencapai 78.033.917 ton pada tahun 2030. Temuan ini mengimplikasikan bahwa perencanaan ketahanan pangan Indonesia dapat menggunakan *Moving Average* sebagai alat *forecasting* yang *reliable* untuk meningkatkan efektivitas kebijakan pangan jangka panjang.

Kata Kunci: *exponential smoothing*, *moving average*, *naive model*, peramalan, sereal

Abstract - Cereals are the primary food staple for the people of Southeast Asia, particularly in Indonesia. This makes cereals a key indicator of a country's food security, and forecasting cereal production levels is essential to support more effective planning in meeting the food needs of the Indonesian population. This study aimed to compare the best methods for forecasting cereal production in Indonesia using the *Moving Average*, *Exponential Smoothing*, and *Naive Model* methods. This study utilized secondary data from the World Bank and the United Nations Food and Agriculture Organization (FAO) regarding Indonesia's cereal production from 1961 to 2020 and performed forecasts using these three methods with validation parameters MAD and MAPE. The results indicate that the *Moving Average* with a 2-period is the best method, yielding a MAD of 1,082,453 tons and an MAPE of 2.59%, significantly more accurate than *Exponential Smoothing* (MAPE 5.20%) and the *Naive Model* (MAPE 10.81%). Cereal production for the next 10 years (2021–2030) is also projected to show consistent growth, with a forecast of 78,033,917 t by 2030. These findings imply that Indonesia's food security planning can utilize the *Moving Average* as a reliable forecasting tool to enhance the effectiveness of long-term food policies.

Kata Kunci: *cereal*, *exponential smoothing*, *forecasting*, *moving average*, *naive model*

PENDAHULUAN

Sektor pertanian memiliki peranan yang sangat penting bagi kehidupan dan perekonomian khususnya di Asia Tenggara. Diketahui juga bahwa mayoritas masyarakat Asia Tenggara masih bergantung terhadap sektor pertaniannya guna mencukupi kebutuhan pangan dan gizi (Sukatoni *et al.*, 2026). Salah satu jenis bahan pangan utama yang hampir tidak bisa tergantikan dan selalu dikonsumsi oleh masyarakat Asia Tenggara adalah makanan berjenis sereal (gandum, beras, jagung, dan biji-bijian). Selain

itu permintaan konsumsi sereal di wilayah Asia Tenggara kian hari juga kian mengalami peningkatan yang signifikan, terkhusus di Indonesia (Retiaty *et al.*, 2025). Hasil produksi sereal seringkali dijadikan indikator ketahanan pangan di seluruh Dunia (Grote *et al.*, 2021). Hal ini menyebabkan perlu adanya peramalan dan prediksi guna memperkirakan produksi sereal di Indonesia supaya tidak terjadi *over demand* atau *over supply*.

Peramalan merupakan suatu kegiatan untuk memprediksi atau memperkirakan kejadian di masa yang akan datang dengan mempertimbangkan data



dari masa lampau atau data *historical* (Park & Zach, 2025). Peramalan juga digunakan sebagai alat bantu untuk perencanaan yang efektif terhadap suatu kondisi. Terdapat beberapa metode yang sering digunakan dalam peramalan antara lain *Moving Average* dan *Naïve* model. *Moving average* merupakan metode peramalan yang dilakukan dengan menggunakan sekelompok nilai *historical* yang dirata-rata lalu nilainya digunakan sebagai ramalan periode yang akan datang (Kumila et al., 2019). Di sisi lain, *Exponential Smoothing* merupakan metode peramalan yang diterapkan dengan memberikan bobot secara eksponensial atau bertingkat pada data-data terbarunya sehingga data-data terbaru tersebut akan mendapatkan bobot yang lebih besar (Junthopas & Wongoutong, 2023). Sedangkan *Naïve Model* merupakan metode peramalan yang menganggap bahwa peramalan periode berikutnya sama dengan nilai aktual periode sebelumnya (Armita et al., 2020).

Penelitian terdahulu banyak menunjukkan bahwa *Moving Average*, *Exponential Smoothing* dan *Naïve Model* menjadi tiga metode yang paling sering digunakan karena memiliki tingkat akurasi yang baik dibandingkan dengan metode yang lain. Hal ini dibuktikan dengan penelitian terdahulu dimana dilakukan peramalan terhadap permintaan pasar dan pengendalian persediaan bahan baku pada industri minuman ringan dengan menggunakan *Moving Average* dan *Exponential Smoothing* dengan akurasi yang baik (Karima et al., 2022). Penelitian lain juga melakukan peramalan namun dengan menggunakan *Moving Average* dan *Exponential Smoothing* untuk memprediksi permintaan produk roti pada suatu industri, hasilnya pun menunjukkan akurasi yang baik (Guslan & Fatimah, 2021). Di sisi lain, penelitian peramalan produksi pangan sereal di Saudi Arabia dengan menggunakan pendekatan *Autoregressive Integrated Moving Average* (ARIMA) juga pernah dilakukan dengan menghasilkan performa yang baik yaitu *relative error* sebesar 1,39% (Abdalla, 2025).

Namun sayangnya hingga saat ini studi yang membandingkan model peramalan statistik yang ditujukan untuk produksi komoditas pertanian masih bersifat terbatas, khususnya pada komoditas sereal yang menjadi komoditas pokok bagi masyarakat Indonesia. Oleh karena itu tujuan dalam penelitian ini adalah untuk membandingkan metode terbaik dalam proses peramalan produksi sereal di Indonesia menggunakan metode *Moving Average*, *Exponential Smoothing* dan *Naïve Model*.

METODE PENELITIAN

1. Tempat dan Waktu Penelitian

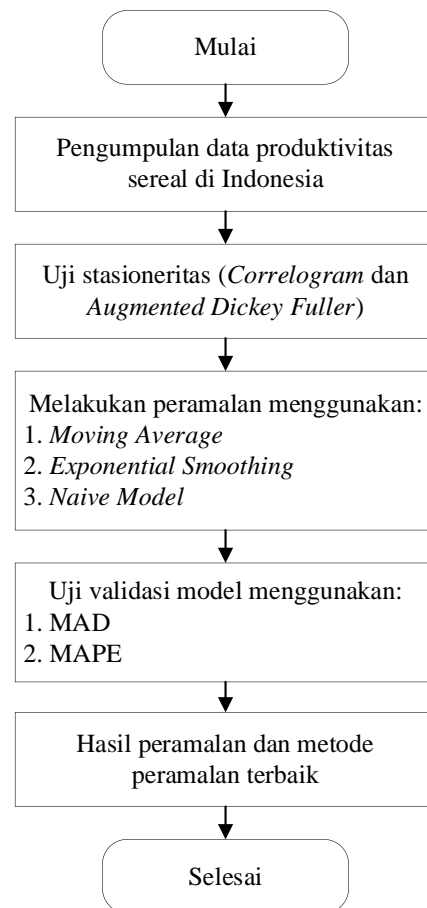
Penelitian ini dilaksanakan di Departemen Teknologi Industri Pertanian, Fakultas Teknologi Pertanian, Universitas Jember, Kabupaten Jember dengan rentang waktu mulai Bulan Desember 2022 hingga Januari 2023.

2. Jenis Data

Dalam penelitian ini, data yang digunakan adalah data dengan jenis sekunder. Data sekunder adalah data yang didapatkan melalui pihak lain, dari subjek penelitiannya tidak secara langsung diterima oleh peneliti. Data sekunder juga sering disebut sebagai data tangan kedua. Data sekunder pada penelitian ini berupa produksi sereal Indonesia pada tahun 1961-2020. Data sekunder ini bersumber dari *World Bank* dan *United Nation Food Agriculture Organization* (FAO) sebagai pihak yang bertanggung jawab terhadap bidang pangan di seluruh Dunia.

3. Prosedur Penelitian

Penelitian dilakukan dengan meramalkan produksi sereal di Indonesia pada masa mendatang dengan menggunakan data *historical* melalui tiga metode antara lain *Moving Average*, *Exponential Smoothing* dan *Naïve Model*. Adapun diagram alir pada penelitian ini disajikan pada Gambar 1.



Gambar 1. Diagram Alir Penelitian

4. Stasioneritas Data

Data yang digunakan dalam peramalan *time series* harus memiliki kestasioneran yang baik dengan memperhatikan nilai *mean*, *variance* dan fungsi autokorelasi yang konstan terhadap waktu. Oleh karena itu pada penelitian ini digunakan grafik dan uji

Augmented Dicky Fuller (ADF) dengan menggunakan *software* Eviews 12. Hipotesis uji stasioneritas disajikan sebagai berikut:

H0: $\rho = 0$ terdapat akar unit, data tidak stasioner

H_a : $\rho \neq 0$ tidak terdapat akar unit, data stasioner

5. Moving Average

Dalam melakukan peramalan menggunakan *Moving Average*, rumus yang digunakan adalah sebagai berikut (Heizer & Render, 2019):

$$\text{Moving average} = \frac{1}{n} \sum_{i=1}^n A_t \dots \dots \dots [1]$$

Keterangan:

N = Total periode

A_t = Data aktual periode -t

6. Exponential Smoothing

Dalam melakukan peramalan menggunakan *Exponential Smoothing*, rumus yang digunakan adalah sebagai berikut (Pandit et al., 2022):

$$F_{t+1} = aY_t + (1 - a)F_t \dots \dots \dots [2]$$

Keterangan:

F_{t+1} = Nilai peramalan untuk satu masa kedepan

Y_t = Nilai aktual pada periode ke-t

F_t = Nilai ramalan pada periode ke-t

a = Konstanta pemulusan (0 < a < 1)

7. Naïve Model

Metode *Naïve Model* merupakan metode yang digunakan sebagai pembandingan karena kemudahannya dalam penggunaannya pada berbagai kasus peramalan. Dalam melakukan peramalan menggunakan *Naïve Model*, rumus yang digunakan adalah sebagai berikut (Beck et al., 2025):

$$X_{t+1} = X_t \dots \dots \dots [3]$$

Keterangan:

X_t = Nilai aktual pada periode ke-t

8. Uji Keakuratan Model

Dalam pengujian keakuratan model, terdapat dua cara yang digunakan yaitu dengan mengukur *Mean Absolute Deviation* (MAD) dan *Mean Absolute Percentage Error* (MAPE). MAD merupakan rata-rata *error* absolut pada periode tertentu (Pinsky, 2025). MAPE merupakan persentase kesalahan hasil peramalan terhadap nilai aktual di periode tertentu yang selanjutnya diklasifikasikan tinggi atau rendah (Chicco et al., 2021). Adapun rumus MAD dan MAPE disajikan berikut:

$$\text{MAD} = \frac{\sum |X_t - F_t|}{n} \dots \dots \dots [4]$$

Keterangan:

X_t = Nilai aktual pada periode ke-t

F_t = Nilai peramalan pada periode ke-t

N = Jumlah periode

$$\text{MAPE} = \frac{100}{n} \sum \left| \frac{X_t - F_t}{X_t} \right| \dots \dots \dots [5]$$

Keterangan:

X_t = Nilai aktual pada periode ke-t

F_t = Nilai peramalan pada periode ke-t

HASIL DAN PEMBAHASAN

1. Uji Stasioneritas Data

Uji stasioneritas data merupakan kondisi data yang tidak dipengaruhi oleh waktu. Data yang digunakan didapatkan dari *World Bank* dan *United Nation Food Agriculture Organization* (FAO) yang diambil mulai dari tahun 1961-2020. Hasil stasioneritas data produksi sereal di Indonesia disajikan pada Gambar 2.



Gambar 2. Grafik Data *Time Series* Produksi Sereal di Indonesia Terkini

Berdasarkan grafik yang disajikan di atas, dapat diketahui bahwa terbentuk pola kenaikan yang konstan dan stabil dari waktu ke waktu. Guna memastikan asumsi stasioner sudah terpenuhi, selanjutnya dilakukan pengujian menggunakan pengujian ADF. Adapun hasil pengujian stasioneritas pada data produksi sereal di Indonesia disajikan pada Tabel 1.

Tabel 1. Hasil Uji *Augmented Dicky Fuller*

ADF test statistic	T-statistic	Prob.
	-7.965	0.000
Critical values:	1%	-3.550
	5%	-2.913
	10%	-2.594

Sumber: Peneliti (2024)

Hasil menunjukkan bahwa nilai *T-statistic* lebih kecil daripada nilai kritis pada tabel, selain itu nilai probabilitas juga menunjukkan angka yang lebih kecil daripada 0,05. Hal ini mengindikasikan bahwa H0 ditolak, dan H1 gagal ditolak sehingga dapat diambil suatu kesimpulan bahwa data yang digunakan sudah memiliki sifat stasioner.

2. Peramalan *Moving Average*

Peramalan *Moving Average* dilakukan dengan menggunakan beberapa variasi periode antara lain 2 periode, 3 periode, 4 periode, 5 periode, dan 6 periode. Hasil yang terbaik akan digunakan sebagai

perbandingan dengan metode yang lainnya. Adapun hasil peramalan menggunakan *Moving Average* disajikan pada Tabel 2.

Tabel 2. Hasil Peramalan Produksi Sereal Indonesia dengan Beberapa Variasi Periode

Periode	MAD	MAPE
2	1.082.453	2,59%
3	1.642.506	3,71%
4	2.054.453	4,74%
5	2.542.052	5,82%
6	3.063.587	7,04%

Berdasarkan hasil pengamatan dapat diketahui pada tabel 2 bahwa hasil terbaik ditunjukkan oleh *Moving Average* dengan 2 periode yang dirata-rata di mana memiliki nilai MAD dan MAPE yang terkecil yaitu MAD sebesar 1.082.453,117 dan MAPE 2,5910%. Nilai MAD dan MAPE menunjukkan tingkat akurasi peramalan yang mendekati nilai actual sehingga semakin kecil nilai MAD dan MAPE maka tingkat kesalahan dari peramalan periode tersebut paling sedikit (Kusyanto et al., 2020).

Hasil terbaik yang didapatkan mengonfirmasi bahwa perata-rataan dua periode terakhir mampu mengurangi *noise* tanpa menghilangkan informasi tren yang signifikan. Nilai MAD dan MAPE yang kecil mengindikasikan tingkat kesalahan peramalan minimal, sehingga tingkat kebenaran prediksi semakin besar. Hal ini sejalan dengan kajian terdahulu yang menemukan bahwa periode yang lebih pendek pada *Moving Average* memberikan sifat yang lebih responsif namun rentan terhadap *noise* (Abudy et al., 2024). Oleh karena itu, penentuan periode pada model prediksi membutuhkan pertimbangan karena akan tercipta tradeoff antara responsivitas dan stabilitas model.

Secara teoritis, *Moving Average* dengan periode pendek memberikan keseimbangan optimal antara responsivitas dan stabilitas melalui pemulusan fluktuasi yang dilakukan secara acak. Penelitian terkini juga menunjukkan bahwa model *Moving Average* dengan periode 3 menghasilkan MAD, MAE, MAPE yang lebih baik dibandingkan performa periode di atasnya (Huriati et al., 2022).

3. Peramalan *Exponential Smoothing*

Peramalan *Exponential Smoothing* merupakan salah satu metode yang dilakukan dengan menggunakan beberapa variasi alpha antara lain 0,1 alpha, 0,3 alpha, 0,5 alpha, 0,7 alpha, dan 0,9 alpha. Hasil yang terbaik akan digunakan sebagai perbandingan dengan metode yang lainnya untuk dilihat mana yang lebih efektif dan memiliki nilai error yang rendah. Hasil peramalan menggunakan *Exponential Smoothing* disajikan pada Tabel 3.

Tabel 3. Hasil Peramalan Produksi Sereal Indonesia dengan Beberapa Variasi Alpha

Alpha	MAD	MAPE
0,1	9.986.468	20,92%
0,3	4.001.834	9,13%
0,5	2.745.646	6,36%
0,7	2.344.141	5,49%
0,9	2.194.362	5,20%

Berdasarkan dari tabel 3 diatas dapat diketahui bahwasannya nilai MAD dan MAPE terendah yaitu pada variasi alpha 0,9 di mana didapatkan nilai MAD yaitu 2.194.362 dan nilai MAPE yaitu 5,20% yang artinya peramalan dengan menggunakan metode *Exponential Smoothing* dengan variasi alpha 0,9 memiliki tingkat eror terkecil sehingga dapat dijadikan acuan untuk dijadikan peramalan pada masa yang mendatang sehingga dapat diambil kebijakan yang sesuai dan tidak merugikan.

Parameter alpha (α) pada *Exponential Smoothing* memiliki peran penting dengan tujuan untuk dijadikan parameter pemulusan agar dapat memberikan ramalan yang optimal dengan nilai kesalahan terkecil (Goltosos et al., 2022). Selain itu, *Exponential Smoothing* efektif diterapkan pada data yang bersifat stasioner, sedangkan pada pendekatan data deret waktu yang fluktuatif atau tidak teratur, *Exponential Smoothing* tidak efektif (Mironov et al., 2024). Hal ini menunjukkan bahwa data produksi sereal di Indonesia cenderung stasioner. Hasil juga menunjukkan bahwa peningkatan nilai alpha secara konsisten mampu mengurangi kesalahan prediksi, nilai alpha yang kecil (0,1-0,3) memberikan proses *smoothing* yang terlalu kuat sehingga model terlalu tenang dan tertinggal dalam mengikuti kenaikan produksi, hal ini menciptakan suatu bias sistematis negatif terhadap nilai aktual pada periode berikutnya (Vallejo-Huanga & Proaño, 2026).

4. Peramalan *Naïve Model*

Peramalan *Naïve Model* dilakukan dengan menggunakan data *timeseries* dengan data aktual yang didapatkan sebelumnya. Hasil yang terbaik akan digunakan sebagai perbandingan dengan metode yang lainnya. Adapun hasil peramalan menggunakan *Naïve Model* disajikan pada Tabel 4.

Tabel 4. Hasil Peramalan Produksi Sereal Indonesia dengan *Naïve Model*

Metode	MAD	MAPE
<i>Naïve Model</i>	4.681.295	10,81%

Berdasarkan hasil penelitian yang dilakukan dengan menggunakan *Naïve Model* dapat diketahui bahwasannya hasil yang didapatkan yaitu nilai MAD sebesar 4.681.295 dan nilai MAPE sebesar 10,81%. Dalam penerapannya, *Naïve Model* sering digunakan sebagai *benchmark* dengan metode peramalan lain.

Hal ini dikarenakan *Naïve Model* memiliki efektivitas pada data dengan pola *random walk* atau memiliki autokorelasi tinggi antarperiode (Beck et al., 2025).

Persistensi nilai di berbagai periode waktu pada dataset yang dimiliki menunjukkan bahwa dataset memiliki sifat autokorelasi dimana nilai saat ini dipengaruhi oleh nilai sebelumnya (Afrianto et al., 2025). Penelitian terdahulu juga menunjukkan bahwa model canggih seperti ARIMA dan LSTM meskipun memiliki kemampuan menangani pola yang kompleks, namun belum dapat mengungguli *Naïve Model* pada dataset yang didominasi oleh autokorelasi tinggi atau perilaku *random walk* yang dimiliki dataset (Baráth et al., 2026). Hal ini menjadikan *Naïve model* sering juga disebut sebagai model *less is more* dalam peramalan.

5. Komparasi Keakuratan Model

Berdasarkan perhitungan yang telah dilakukan sebelumnya dengan menggunakan berbagai macam metode dapat dijabarkan hasil perhitungan peramalan produksi sereal Indonesia pada tahun 1961-2020. Berbagai metode yang digunakan di atas selanjutnya diambil yang terbaik dan dibandingkan dengan menggunakan parameter MAD dan MAPE. Adapun hasil perbandingan performa disajikan pada tabel 5 dan hasil peramalan selama 10 tahun kedepan dari ketiga model disajikan pada Tabel 6.

Tabel 5. Hasil Performa Peramalan Produksi Sereal Indonesia dengan Beberapa Variasi Metode

Metode Peramalan	MAD	MAPE
<i>Moving Average</i> (periode 2)	1.082.453	2,59%
<i>Exponential Smoothing</i> (0.9)	2.194.362	5,20%
<i>Naïve Model</i>	4.681.295	10,81%

Tabel 6. Proyeksi Peramalan Produksi Sereal di Indonesia Selama 10 Tahun

Tahun	MA (2)	ES (0.9)	<i>Naïve</i>
2021	77.295.467	78.485.190	82.126.145
2022	77.348.270	78.613.185	81.612.842
2023	77.447.966	78.741.389	79.649.237
2024	77.524.340	78.869.802	80.265.041
2025	77.612.519	78.998.425	81.045.271
2026	77.694.930	79.127.257	80.774.612
2027	77.780.364	79.256.299	80.564.713
2028	77.864.423	79.385.552	80.793.955
2029	77.949.307	79.515.015	80.926.399
2030	78.033.917	79.644.690	80.896.633

Berdasarkan dari hasil data peramalan dengan menggunakan variasi metode dapat diketahui bahwasannya nilai MAD dan MAPE yang terkecil didapatkan dengan menggunakan metode peramalan *Moving Average* yang menunjukkan nilai MAD sebesar 1.082.453 dan nilai MAPE sebesar 2,59%. Meskipun data produksi sereal Indonesia menunjukkan

kecenderungan meningkat selama periode 1961–2020, pola kenaikan tersebut berlangsung secara bertahap dan relatif stabil, tanpa adanya lonjakan ekstrem atau perubahan struktur yang tajam. Hasil uji stasioneritas juga menunjukkan bahwa data memiliki pola yang cukup stabil untuk digunakan dalam proses peramalan. Pada periode terakhir, khususnya 2010–2020, volatilitas data cenderung lebih rendah sehingga *Moving Average* periode pendek menjadi lebih efektif karena mampu menangkap perubahan terbaru tanpa terlalu sensitif terhadap fluktuasi acak.

Moving Average periode 2 memiliki kemampuan untuk menangkap tren terbaru tanpa terjebak pada pola historis yang sudah usang atau asumsi tren palsu yang sering menjeratkan model parametrik. Pada data 60 tahun dengan banyaknya *shock*, perubahan kebijakan eksternal, dan anomali cuaca, kemampuan adaptasi ini sangat krusial. Berbeda dengan *Naïve* yang tetap rigid pada nilai terakhir, *Moving Average* periode 2 memberikan bobot seimbang antara kondisi saat ini dan tahun sebelumnya sehingga tercipta penyeimbang alami yang meredam fluktuasi acak. Hal ini menjadikan *Moving Average* periode 2 menghasilkan nilai error yang lebih rendah yaitu MAPE 2,59% dibandingkan *Exponential Smoothing* (5.20%) dan *Naïve* (10.81%).

Evaluasi pada *Exponential Smoothing*, menunjukkan hasil yang cukup baik namun cenderung terlalu responsif terhadap anomali dan *noise* jangka pendek sehingga menghasilkan prediksi yang *overfitted* pada pola yang mungkin tidak berlanjut (Pritularga et al., 2023). Fenomena *overfitting* ini menjadi suatu permasalahan ketika dipertemukan dengan data yang memiliki periode stagnasi, penurunan sementara, dan lonjakan tidak terduga seperti yang diamati pada produksi sereal Indonesia. Sebaliknya, *Moving Average* periode 2 dengan periode yang singkat namun terbatas menciptakan mekanisme *filtering* yang lebih robust, terutama pada fase stabilisasi data yang mulai terlihat jelas setelah tahun 2010. Analisis mendalam terhadap data 2010-2020 menunjukkan bahwa produksi sereal memasuki fase stabilisasi dengan pertumbuhan bertahap sebesar +0.1631% per tahun. Pada fase ini, *Moving Average* dengan periode pendek lebih superior karena dapat menangkap momentum pelan-pelan ini tanpa membuat asumsi tren *linear* yang sering terbukti salah atau kompleksitas model yang tidak perlu.

Evaluasi empiris pada *Naïve Model* menunjukkan performa yang kurang baik dengan MAPE mencapai 10,81% dan menjadi error tertinggi diantara semua model yang diuji. Hal ini terjadi karena *Naïve Model* hanya menggunakan nilai terakhir tanpa mempertimbangkan dinamika terbaru atau tren agregat data, menjadikannya kurang adaptif terhadap perubahan bertahap dan

momentum yang teramati dalam data produksi sereal selama 60 tahun.

Dukungan untuk penggunaan *Moving Average* juga datang dari literatur forecasting terkini. Hasil kompetisi M dalam berbagai literatur peramalan memang menunjukkan bahwa model sederhana memiliki performa baik, namun dengan caveat penting dimana kesederhanaan harus dikalibrasi dengan relevansi empiris dan *adaptivity*. Kombinasi sifat *simplicity* dengan *adaptivity* seperti yang dimiliki *Moving Average* sering mengungguli model yang murni sederhana seperti *Naïve* maupun model kompleks pada datasets dengan karakteristik serupa. Pada konteks data 60 tahun dengan banyaknya variabel tidak terkendali seperti perubahan teknologi pertanian, kebijakan harga, dan kondisi iklim ekstrem (Makridakis et al., 2018).

Dengan nilai MAPE 2,59%, *Moving Average* dengan periode 2 adalah pilihan metodologis yang paling sesuai untuk forecasting jangka panjang produksi sereal Indonesia. Model ini mampu memprediksi tren 10 tahun ke depan (2021-2030) dengan pertumbuhan konsisten sebesar 2.06%, mencerminkan momentum berkelanjutan yang realistis berdasarkan evidensi empiris terbaru dan karakteristik data yang terobservasi selama periode stabilisasi terakhir.

6. Implikasi Manajerial

Berdasarkan studi yang telah dilakukan, didapatkan implikasi bahwa instansi pemerintah, khususnya kementerian yang menangani sektor pangan dan pertanian, dapat menggunakan *Moving Average* sebagai alat peramalan awal untuk memproyeksikan produksi sereal pada periode berikutnya. Penggunaan metode ini lebih efisien karena mudah diterapkan, tidak memerlukan perangkat lunak yang rumit, dan dapat dilakukan secara cepat menggunakan data historis.

Bagi pemerintah daerah dan pelaku industri pangan, hasil peramalan dapat dimanfaatkan untuk menyusun strategi distribusi, pengadaan stok, serta pengelolaan cadangan pangan. Ketika proyeksi produksi menunjukkan potensi penurunan produksi, pemerintah dapat lebih dini mengambil langkah mitigasi seperti meningkatkan impor, memperkuat distribusi antarwilayah, atau menambah cadangan pangan nasional. Sebaliknya, apabila hasil peramalan menunjukkan peningkatan produksi, maka pemerintah dapat mempersiapkan kapasitas penyimpanan, distribusi, dan pemasaran agar hasil panen tidak menyebabkan kelebihan pasokan dan penurunan harga di tingkat petani.

Implikasi lain yang penting adalah perlunya integrasi hasil peramalan dengan kebijakan ketahanan pangan nasional. Peramalan produksi sereal dapat digunakan sebagai dasar dalam menyusun kebijakan subsidi pupuk, bantuan benih, penentuan target produksi, serta perencanaan luas tanam pada musim berikutnya. Dengan demikian,

keputusan yang diambil tidak bersifat reaktif namun antisipatif berdasarkan data historis dan proyeksi.

KESIMPULAN

Berdasarkan penelitian yang telah dilakukan didapati bahwa *Moving Average* periode 2 memberikan hasil peramalan terbaik dibandingkan metode *Exponential Smoothing* dan *Naïve Model*, sehingga dapat dijadikan acuan awal dalam perencanaan persediaan sereal. Namun, penelitian ini masih memiliki keterbatasan karena hanya menggunakan metode peramalan sederhana dan belum mempertimbangkan faktor eksternal seperti perubahan iklim, fluktuasi harga, kebijakan impor, maupun kondisi ekonomi yang dapat memengaruhi ketersediaan sereal. Untuk penelitian selanjutnya, disarankan menggunakan metode peramalan yang lebih kompleks dan adaptif seperti ARIMA, Holt-Winters, maupun pendekatan machine learning seperti *Long Short-Term Memory* (LSTM) agar mampu menangkap pola tren, musiman, dan fluktuasi data dengan lebih baik.

Secara praktis, hasil penelitian ini dapat menjadi dasar bagi pemerintah dan pelaku industri pangan dalam menentukan kebijakan persediaan sereal secara lebih efektif. Peramalan yang akurat dapat membantu mengurangi risiko kekurangan maupun kelebihan stok, menjaga stabilitas harga pangan, serta mendukung ketahanan pangan nasional. Bagi pemerintah, hasil peramalan dapat digunakan sebagai dasar dalam pengambilan keputusan terkait kebijakan impor, distribusi cadangan pangan, dan perencanaan produksi domestik.

REFERENSI

- Abdalla, S. M. (2025). Forecasting cereal food production in the Kingdom of Saudi Arabia using the autoregressive integrated *Moving Average* model. *Food Research*, 9, 6–12. [https://doi.org/10.26656/fr.2017.9\(2\).418](https://doi.org/10.26656/fr.2017.9(2).418)
- Abudy, M. M., Kaplanski, G., & Mugeran, Y. (2024). Market timing with *Moving Average* distance: International evidence. *Journal of International Financial Markets, Institutions and Money*, 97, 102065. <https://doi.org/10.1016/j.intfin.2024.102065>
- Afrianto, Y., Munadi, R., Setyorini, & Widyanto, T. (2025). Performance assessment of time series forecasting models for simple network management protocol-based hypervisor data. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 14(2), 1150–1163. <https://doi.org/10.11591/ijai.v14.i2.pp1150-1163>

- Arnita, Novriyana, D., & Marpaung, F. (2020). Perbandingan Metode Single Exponential Smoothing, Naïve Model, dan SARIMA untuk Peramalan Curah Hujan Di Kota Medan. *Jurnal Matematika, Statistika & Komputasi*, 17(1), 117–128. <https://doi.org/10.20956/jmsk.v>
- Baráth, Z., Veres, P., & Bányai, Á. (2026). Beyond Traditional Forecasting Methods: Evaluating LSTM Performance on Diverse Time Series. In *Mathematics*, 14(5), 838. <https://doi.org/10.3390/math14050838>
- Beck, N., Dovern, J., & Vogl, S. (2025). Mind the Naïve forecast! a rigorous evaluation of forecasting models for time series with low predictability. *Applied Intelligence*, 55(6), 395. <https://doi.org/10.1007/s10489-025-06268-w>
- 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, e623. <https://doi.org/10.7717/peerj-cs.623>
- Darfial, G., & Fatimah, L. (2021). Analisis Ramalan Permintaan Produk Roti Industri Tiara Rizki. *Jurnal Bisnis Logistik*, 11(02), 78–91.
- Goltsos, T. E., Syntetos, A. A., Glock, C. H., & Ioannou, G. (2022). Inventory – forecasting: Mind the gap. *European Journal of Operational Research*, 299(2), 397–419. <https://doi.org/10.1016/j.ejor.2021.07.040>
- Grote, U., Fasse, A., Nguyen, T. T., & Erenstein, O. (2021). Food Security and the Dynamics of Wheat and Maize Value Chains in Africa and Asia. *Frontiers in Sustainable Food Systems*, 4. <https://doi.org/10.3389/fsufs.2020.617009>
- Heizer, J., & Render, B. (2019). *Manajemen Operasi*. Jakarta: Salemba Empat.
- Huriati, P., Erianda, A., Alanda, A., Meidelfi, D., Rasyidah, -, Defni, -, & Suryani, A. I. (2022). Implementation of The Moving Average Method for Forecasting Inventory in CV. Tre Jaya Perkasa. *International Journal of Advanced Science Computing and Engineering*, 4(2 Special Edition), 67–75. <https://doi.org/10.62527/ijasce.4.2.77>
- Junthopas, W., & Wongoutong, C. (2023). Setting the Initial Value for Single Exponential Smoothing and the Value of the Smoothing Constant for Forecasting Using Solver in Microsoft Excel. *Applied Sciences (Switzerland)*, 13(7). <https://doi.org/10.3390/app13074328>
- Karima, H. Q., Saputra, M. A., & Romadlon, F. (2022). Analisis Kapasitas Produksi dan Pemenuhan Permintaan dengan Model Sistem Dinamis pada Industri Semen. *Unistek*, 9(1), <https://doi.org/10.33592/unistek.v9i1.1919>
- Kumila, A., Sholihah, B., Evizia, E., Safitri, N., & Fitri, S. (2019). Perbandingan Metode Moving Average dan Metode Naïve Dalam Peramalan Data Kemiskinan. *Jurnal Teori Dan Aplikasi Matematika (JTAM)*, 3(1), 65. <https://doi.org/10.31764/jtam.v3i1.764>
- Kusyanto, Suhardi, D., & Awaluddin, R. (2020). Peramalan Penjualan Keramik Menggunakan Metode Moving Average Dan Exponential Smoothing Pada Usaha Agus Keramik. *Jurnal Ekonomi Akuntansi Dan Manajemen*, 1(1).
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS One*, 13(3), e0194889. <https://doi.org/10.1371/journal.pone.0194889>
- Mironov, A. N., Pirogov, S. U., Petuhov, A. I., Sinilov, V. K., & Shestopalova, O. L. (2024). Uneven time series forecasting using a modified Exponential Smoothing method. *E3S Web of Conferences*, 531. <https://doi.org/10.1051/e3sconf/202453103020>
- Pandit, P., Krishnamurthy, K. N., & Bakshi, B. (2022). Chapter 22 - Prediction of crop yield and pest-disease infestation. In *Intelligent Data-Centric Systems* (pp. 375–393). Academic Press. <https://doi.org/10.1016/B978-0-12-823694-9.00021-9>
- Park, M., & Zach, T. (2025). Analysts' forecasting models and uncertainty about the past. *Review of Accounting Studies*, 30(3), 2376–2418. <https://doi.org/10.1007/s11142-025-09898-0>
- Pinsky, E. (2025). Computation and interpretation of mean absolute deviations by cumulative distribution functions. *Frontiers in Applied Mathematics and Statistics*, 11. <https://doi.org/10.3389/fams.2025.1487331>
- Pritularga, K. F., Svetunkov, I., & Kourentzes, N. (2023). Shrinkage estimator for Exponential Smoothing models. *International Journal of Forecasting*, 39(3), 1351–1365.
- Retiaty, F., Andarwulan, N., Palupi, N. S., Ernawati, F., Kazimierczak, R., & Średnicka-Tober, D. (2025). Contribution of Food, Energy, Macronutrients and Fiber Consumption Patterns to Obesity and Other Non-

Communicable Disease Risks in the Indonesian Population. *Nutrients*, 17(9).
<https://doi.org/10.3390/nu17091459>

Sukaton, D. L. A., Bajan, B., & Baer-Nawrocka, A. (2026). A typology of food consumption patterns in ASEAN: A cluster analysis of convergence and divergence (2010-2022).

Jurnal Inovasi Pangan Dan Gizi, 3(1).
<https://doi.org/10.61511/jipagi.v3i1.2751>

Vallejo-Huanga, D., & Proaño, J. (2026). Performance optimization of simple *Exponential Smoothing* forecast model. *Heliyon*, 12(1)