


# Analisis Perbandingan DMA -DES

dalam Prediksi Transaksi Penjualan  
(Meningkatkan Akurasi Melalui Pendekatan Data Time Series)



Riadi Marta Dinata

# Analisis Perbandingan Algoritma DMA DES dalam Prediksi Transaksi Penjualan

(Meningkatkan Akurasi Melalui Pendekatan Data Time Series)

RIADI MARTA DINATA

Copyright © 2024 by ISTN Publishing

Diterbitkan oleh:

**KAMPUS ISTN**

Jl. Moh Kahfi II, Srengseng Sawah, Jagakarsa, Jakarta Selatan  
12640

Penyunting: Abcde Fghijklmn Opqrs

Layout: Team Layout ISTN

Desain Cover: Tuvw Xyz

Terbit: September 2024

ISBN: 978-623-7839-XY-Z

---



# KATA PENGANTAR

Puji syukur kami panjatkan ke hadirat Tuhan Yang Maha Esa, yang telah memberikan kesempatan untuk menyelesaikan buku ini, yang berjudul "**Analisis Perbandingan Algoritma DMA dan DES dalam Prediksi Transaksi Penjualan.**" Buku ini hadir sebagai panduan praktis bagi para praktisi, akademisi, dan peneliti yang berfokus pada analisis prediktif berbasis data time series.

Di era persaingan bisnis yang semakin ketat, kemampuan untuk memprediksi transaksi penjualan dengan akurat menjadi kebutuhan utama. Buku ini mengulas dua algoritma populer, yakni **Double Moving Average (DMA)** dan **Double Exponential Smoothing (DES)**, yang sering digunakan dalam analisis prediktif. Melalui studi kasus nyata, buku ini membandingkan performa kedua algoritma dengan menggunakan metrik akurasi seperti **MAPE, MAE, MSE, RMSE, dan MAD.**

Kami berharap struktur ini dapat memudahkan pembaca memahami dan mengimplementasikan algoritma yang paling sesuai dengan karakteristik data mereka. Semoga buku ini dapat memberikan manfaat yang besar bagi pembaca, baik dalam pengembangan ilmu pengetahuan maupun penerapan di dunia nyata.

Jakarta, Desember 2024

**Penulis**



# Daftar Isi

**Testimoni** --- iii

**Kata Pengantar** --- vi

**Prolog**--- viii

**Daftar Isi** --- ix

Bagian 1 Sejarah Kriptografi--- 1

Bagian 2 Pembagian Jenis Kriptografi --- 17

Bagian 3 Kupas Vigenere Chipper --- 23

Bagian 4 Metodologi Kerja Vigenere Chipper--- 33

Bagian 5 Implementasi Matlab CLI dan GUI --- 38

Bagian 6 Menguji Ketangguhan Aplikasi--- 43

Bagian 7 Hack Vigenere Chipper--- 63

Bagian 8 Perwasitan Woodball --- 73

Bagian 9 Novelty Vigenere Chipper--- 87

Bagian 10 Masa Depan Vigenere Chipper --- 93

**Daftar Pustaka** --- 99

**Tentang Penulis** --- 100

**Lampiran-Lampiran** --- 101





# BAGIAN 1

## Pendahuluan

### 1.1 Pentingnya Prediksi dalam Transaksi Penjualan

Prediksi dalam transaksi penjualan adalah langkah strategis yang menjadi landasan bagi pengambilan keputusan bisnis yang efektif. Dalam dunia yang terus berubah, perusahaan menghadapi tantangan untuk memahami kebutuhan pasar yang dinamis dan perilaku pelanggan yang tidak selalu



dapat diprediksi. Dengan prediksi yang akurat, perusahaan dapat:

**1. Mengelola Inventaris dengan Efisien:**

- Prediksi penjualan memungkinkan perusahaan menghindari masalah overstocking (kelebihan stok) dan understocking (kekurangan stok). Keduanya memiliki dampak finansial yang signifikan, baik berupa biaya penyimpanan maupun hilangnya peluang penjualan.

**2. Merencanakan Produksi secara Optimal:**

- Dengan memahami pola permintaan, perusahaan dapat menyelaraskan proses produksi dengan kebutuhan pasar, sehingga mengurangi pemborosan sumber daya.

**3. Mengoptimalkan Strategi Pemasaran:**

- Prediksi yang baik memberikan wawasan tentang waktu terbaik untuk meluncurkan promosi atau menyesuaikan harga, sehingga menarik lebih banyak pelanggan.

**4. Mengambil Keputusan Bisnis yang Tepat:**

- Informasi prediksi membantu perusahaan merancang strategi jangka panjang, seperti



ekspansi pasar atau peluncuran produk baru.

Dalam dunia yang berbasis data, prediksi penjualan bukan lagi sekadar pilihan, tetapi kebutuhan untuk mempertahankan daya saing. Oleh karena itu, pemilihan metode prediksi yang tepat menjadi kunci untuk mencapai hasil yang maksimal.

## 1.2 Penjelasan Algoritma DMA dan DES

### Double Moving Average (DMA):

- DMA adalah algoritma sederhana yang menggunakan dua lapis rata-rata bergerak untuk mengurangi noise dan menangkap pola tren dalam data time series.
- Algoritma ini bekerja dengan menghitung rata-rata bergerak pertama (Single Moving Average) untuk menghaluskan data, kemudian menerapkan rata-rata bergerak kedua (Double Moving Average) untuk menangkap tren yang lebih jelas.
- **Kelebihan:**
  - Mudah diimplementasikan.
  - Cocok untuk data dengan tren stabil.
- **Kekurangan:**



- Kurang fleksibel untuk data dengan fluktuasi tinggi atau tren non-linier.

### **Double Exponential Smoothing (DES):**

- DES adalah pengembangan dari metode Exponential Smoothing yang menambahkan komponen tren. Algoritma ini memanfaatkan dua parameter utama:
  - **Alpha ( $\alpha$ )** untuk melunakkan data aktual.
  - **Beta ( $\beta$ )** untuk melunakkan tren.
- **Kelebihan:**
  - Mampu menangkap pola tren linier.
  - Fleksibel untuk data dengan tren yang berubah secara bertahap.
- **Kekurangan:**
  - Membutuhkan penyesuaian parameter yang optimal untuk hasil terbaik.

### **Tujuan Penelitian:**

- Membandingkan kinerja algoritma DMA dan DES dalam memprediksi transaksi penjualan pada tiga jenis produk dengan karakteristik data yang berbeda.



- Menentukan algoritma yang paling cocok untuk data dengan tren stabil, fluktuasi ringan, dan fluktuasi tinggi.
- Mengevaluasi akurasi prediksi menggunakan metrik MAPE, MAE, MSE, RMSE, dan MAD.

### **Manfaat Penelitian:**

- **Bagi Praktisi Bisnis:** Memberikan panduan dalam memilih algoritma prediksi yang sesuai dengan pola data penjualan.
- **Bagi Akademisi:** Menambah wawasan ilmiah dalam perbandingan algoritma prediksi berbasis time series.
- **Bagi Teknologi:** Mendorong pengembangan solusi berbasis algoritma prediksi untuk penerapan praktis di dunia bisnis.

### **1.3 Strategi untuk Meningkatkan Akurasi Prediksi dan Membandingkan Algoritma**

Akurasi prediksi sangat dipengaruhi oleh pemilihan algoritma yang sesuai dengan pola data dan parameter yang digunakan. Berikut adalah strategi utama untuk meningkatkan akurasi:



### 1. **Pemilihan Algoritma yang Tepat:**

- Gunakan DMA untuk data dengan tren stabil tanpa fluktuasi signifikan.
- Gunakan DES untuk data dengan tren linier dan fluktuasi ringan hingga sedang.

### 2. **Penyesuaian Parameter:**

- Pada DMA, optimalkan periode ( $M$ ) untuk menangkap pola tren tanpa terlalu banyak noise.
- Pada DES, sesuaikan parameter Alpha ( $\alpha$ ) dan Beta ( $\beta$ ) untuk mengakomodasi tingkat pelunakan data dan tren.

### 3. **Evaluasi Berbasis Metrik:**

- Gunakan MAPE untuk mengukur kesalahan relatif dalam persentase.
- Gunakan MAE untuk memahami kesalahan absolut rata-rata.
- Gunakan MSE dan RMSE untuk mendeteksi kesalahan besar yang signifikan.
- Gunakan MAD untuk menganalisis deviasi absolut yang lebih sederhana.

### 4. **Penggunaan Dataset yang Beragam:**

- Evaluasi algoritma pada dataset dengan tren yang berbeda (stabil, fluktuatif, dan dinamis)



untuk memahami batasan dan keunggulan masing-masing metode.

#### 5. **Eksperimen dengan Kombinasi Parameter:**

- Lakukan percobaan dengan variasi parameter ( $M$  untuk DMA, dan  $\alpha$ ,  $\beta$  untuk DES) untuk menemukan konfigurasi optimal.

Dengan menerapkan strategi ini, penelitian ini tidak hanya membandingkan performa algoritma DMA dan DES, tetapi juga memberikan panduan praktis untuk meningkatkan akurasi prediksi dalam transaksi penjualan.





# BAGIAN 2

## Landasan Teori

### 2.1 Tentang Analisis Time Series

Time series adalah rangkaian data yang dikumpulkan pada interval waktu tertentu, seperti harian, mingguan, bulanan, atau tahunan, yang mencerminkan perubahan suatu variabel seiring waktu. Analisis time series bertujuan untuk



memahami pola-pola yang ada dalam data historis, memprediksi nilai di masa depan, dan memantau perubahan untuk mendeteksi anomali. Data time series memiliki beberapa komponen utama, yaitu tren, musiman, siklik, dan noise. Tren menunjukkan pola jangka panjang dalam data, seperti kenaikan atau penurunan nilai yang konsisten. Musiman menggambarkan pola yang berulang dalam interval tertentu, seperti peningkatan penjualan pada hari raya. Komponen siklik berkaitan dengan fluktuasi jangka panjang yang tidak terikat oleh musim, misalnya siklus ekonomi. Noise mewakili variasi acak yang tidak dapat dijelaskan oleh pola lain dan sering kali muncul sebagai gangguan atau ketidakpastian.

Analisis time series tidak hanya digunakan untuk menggambarkan data historis, tetapi juga untuk memproyeksikan nilai masa depan. Misalnya, dalam bisnis, peramalan penjualan dilakukan untuk mendukung pengelolaan inventaris dan perencanaan produksi yang lebih efisien.

## **2.2 Mekanisme Kerja Algoritma DMA dan DES**

### **Double Moving Average (DMA):**

#### **1. Definisi:**



- DMA adalah pengembangan dari metode Moving Average sederhana yang menambahkan tingkat kedua untuk menghaluskan fluktuasi data.

## 2. Langkah-langkah:

- **Single Moving Average (SMA):** Hitung rata-rata bergerak dari data historis menggunakan periode tertentu (M).

$$SMA_t = \frac{1}{M} \sum_{i=t-M+1}^t X_i$$

- **Double Moving Average (DMA):** Hitung rata-rata dari SMA untuk menangkap tren yang lebih stabil.

$$DMA_t = \frac{1}{M} \sum_{i=t-M+1}^t SMA_i$$

- **Prediksi:** Menggunakan perbedaan antara SMA dan DMA untuk memproyeksikan nilai masa depan.

$$F_{t+k} = 2 \cdot SMA_t - DMA_t + (k * \text{Trend Factor})$$



### 3. Kelebihan:

- Sederhana dan mudah diimplementasikan.
- Cocok untuk data dengan tren linier sederhana.

### 4. Kekurangan:

- Tidak fleksibel untuk data dengan fluktuasi tinggi atau pola musiman.
- Tidak dapat menangkap perubahan tren non-linier.

## Double Exponential Smoothing (DES):

### 1. Definisi:

- DES adalah metode pelunakan eksponensial yang menambahkan komponen tren untuk menangkap perubahan pola data.

### 2. Langkah-langkah:

- **Level (St):** Menghaluskan data aktual berdasarkan parameter  $\alpha$  dan nilai sebelumnya.

$$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} + T_{t-1})$$



- **Trend (Tt):** Menangkap tren perubahan dengan pelunakan parameter  $\beta$ .

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}$$

- **Prediksi (Ft+k):** Proyeksi masa depan menggunakan level dan tren yang dihasilkan.

- $F_{t+k} = S_t + k \cdot T_t$

### 3. Kelebihan:

- Mampu menangkap pola tren linier dan fluktuasi ringan.
- Parameter  $\alpha$  dan  $\beta$  memberikan fleksibilitas.

### 4. Kekurangan:

- Membutuhkan penyesuaian parameter untuk data yang kompleks.
- Tidak menangkap pola musiman.

## 2.3. Penggunaan Metrik Evaluasi

Untuk mengevaluasi akurasi algoritma DMA dan DES, digunakan lima metrik utama:

### 1. MAPE (Mean Absolute Percentage Error):



- Mengukur kesalahan relatif dalam bentuk persentase.
- Cocok untuk membandingkan performa prediksi pada dataset dengan skala berbeda.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100$$

## 2. MAE (Mean Absolute Error):

- Mengukur rata-rata kesalahan absolut tanpa memberikan penalti besar pada kesalahan ekstrem.
- Digunakan untuk memahami kesalahan rata-rata dalam satuan yang sama dengan data.

$$MAE = \frac{1}{n} \sum_{t=1}^n |A_t - F_t|$$

## 3. MSE (Mean Squared Error):

- Memberikan penalti lebih besar pada kesalahan besar, sehingga cocok untuk mendeteksi outlier.



$$MSE = \frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2$$

○

#### 4. **RMSE (Root Mean Squared Error):**

- Akar dari MSE, memberikan hasil dalam skala yang sama dengan data asli.

$$RMSE = \sqrt{MSE}$$

○

#### 5. **MAD (Mean Absolute Deviation):**

- Mengukur deviasi absolut rata-rata, memberikan gambaran sederhana tentang kesalahan prediksi.

$$MAD = \frac{1}{n} \sum_{t=1}^n |A_t - F_t|$$

○

### **Manfaat Metrik:**

- **MAPE:** Membandingkan akurasi prediksi antar dataset.
- **MAE & MAD:** Mengukur kesalahan rata-rata dalam satuan asli.
- **MSE & RMSE:** Deteksi kesalahan besar untuk meminimalkan outlier.



Metrik-metrik ini adalah saling melengkapi. MAPE memberikan gambaran relatif, sedangkan MAE, MSE, RMSE, dan MAD memberikan gambaran absolut. Penggunaan kombinasi metrik ini memungkinkan evaluasi yang lebih komprehensif terhadap performa algoritma prediksi.

# BAGIAN 3

## Metodologi Penelitian

### 3.1 Data yang Digunakan untuk Percobaan

Penelitian ini menggunakan data historis penjualan tiga produk otomotif dari merek BBK HSR, yaitu Toyota, Mitsubishi, dan BMW/Mercy. Data diperoleh dari laporan transaksi penjualan selama beberapa bulan terakhir, yang disusun dalam bentuk time series dengan interval bulanan. Masing-masing dataset memiliki karakteristik yang berbeda, yang memungkinkan evaluasi terhadap kinerja algoritma



Double Moving Average (DMA) dan Double Exponential Smoothing (DES) pada kondisi data yang bervariasi.

Dataset yang digunakan memiliki rincian sebagai berikut:

1. **BBK HSR Toyota**

Dataset ini memiliki pola yang stabil dengan tren linier, tanpa fluktuasi signifikan. Produk ini dipilih untuk menguji performa algoritma pada data dengan karakteristik yang sederhana.

2. **BBK HSR Mitsubishi**

Dataset ini menunjukkan tren yang cukup stabil tetapi memiliki fluktuasi ringan yang mencerminkan perubahan permintaan yang tidak terlalu ekstrem. Produk ini digunakan untuk mengukur kemampuan algoritma dalam menangani data dengan variasi kecil.

3. **BBK HSR BMW/Mercy**

Dataset ini memiliki tren yang lebih dinamis dengan fluktuasi yang tinggi. Produk ini digunakan untuk mengevaluasi ketangguhan algoritma dalam menangani data dengan perubahan yang lebih kompleks.

Semua dataset diolah dalam format time series untuk memastikan bahwa struktur datanya mendukung penerapan algoritma prediksi.

### 3.2 Implementasi Algoritma DMA dan DES

**Double Moving Average (DMA):** Algoritma DMA diterapkan pada masing-masing dataset dengan menggunakan berbagai panjang periode (MMM) untuk mengevaluasi pengaruhnya terhadap akurasi prediksi. Langkah-langkah implementasi adalah sebagai berikut:

1. Menghitung Single Moving Average (SMA) menggunakan formula:

$$SMA_t = \frac{1}{M} \sum_{i=t-M+1}^t X_i$$

Di mana M adalah panjang periode, t adalah waktu saat ini, dan  $X_i$  adalah nilai data aktual.

2. Menghitung Double Moving Average (DMA) dari hasil SMA:

$$DMA_t = \frac{1}{M} \sum_{i=t-M+1}^t SMA_i$$



3. Menghitung nilai prediksi:

$$F_{t+k} = 2 \cdot SMA_t - DMA_t + k \cdot TrendFactor$$

Nilai k menunjukkan langkah prediksi ke depan.

**Double Exponential Smoothing (DES):** Algoritma DES diterapkan dengan kombinasi parameter Alpha ( $\alpha$ ) dan Beta ( $\beta$ ) untuk mengevaluasi fleksibilitas dalam menangkap pola data. Langkah-langkah implementasi adalah sebagai berikut:

1. Menghitung level data yang dilunakkan menggunakan formula:

$$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} + T_{t-1})$$

2. Menghitung komponen tren:

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}$$

3. Menghitung nilai prediksi:

$$F_{t+k} = S_t + k \cdot T_t$$

Kombinasi parameter Alpha ( $\alpha$ ) dan Beta ( $\beta$ ) diatur dari 0.1 hingga 0.4 untuk setiap dataset guna menemukan konfigurasi optimal.

## Metode Evaluasi Hasil Prediksi

Evaluasi hasil prediksi dilakukan dengan menghitung lima metrik utama yang digunakan untuk mengukur akurasi algoritma, yaitu:

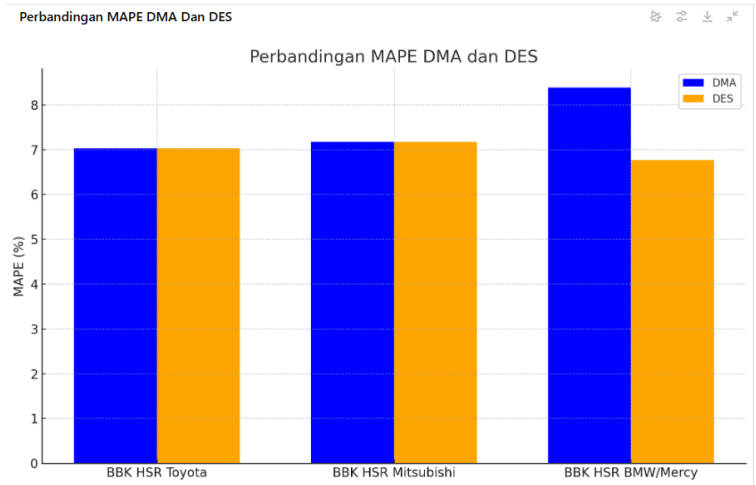
1. **Mean Absolute Percentage Error (MAPE):**

MAPE digunakan untuk mengukur kesalahan relatif dalam bentuk persentase. Formula perhitungannya adalah:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100$$

Di mana  $A_t$  adalah nilai aktual,  $F_t$  adalah nilai prediksi, dan  $n$  adalah jumlah data.






Grafik ini menunjukkan bahwa **DES** unggul pada dataset BBK HSR BMW/Mercy dengan nilai MAPE yang lebih rendah dibandingkan **DMA**. Pada dataset BBK HSR Toyota dan Mitsubishi, MAPE untuk kedua algoritma hampir identik.

2. **Mean Absolute Error (MAE):** MAE mengukur rata-rata kesalahan absolut dalam satuan data asli, dihitung menggunakan:

$$MAE = \frac{1}{n} \sum_{t=1}^n |A_t - F_t|$$

Grafik ini memperlihatkan nilai MAE yang lebih rendah pada **DES** untuk dataset BBK HSR

BMW/Mercy, sementara pada BBK HSR Toyota dan Mitsubishi, nilainya sangat mirip dengan **DMA**.

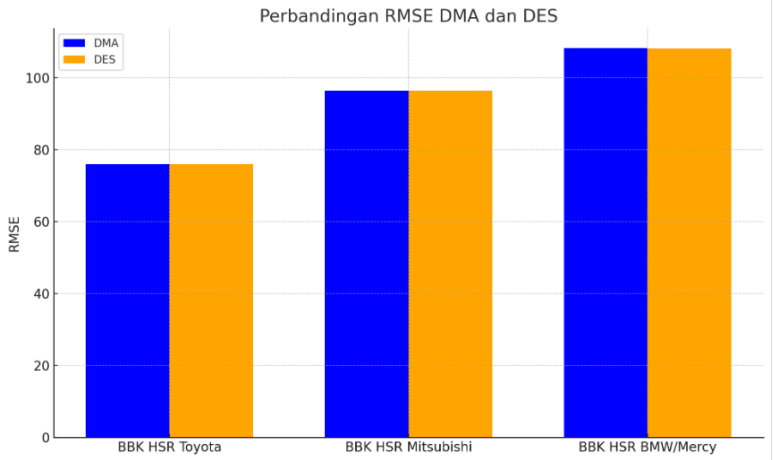


- Mean Squared Error (MSE):** MSE memberikan penalti lebih besar pada kesalahan besar, dihitung dengan:

$$MSE = \frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2$$



Perbandingan RMSE DMA Dan DES



Grafik RMSE menunjukkan pola serupa dengan MAE, di mana **DES** memberikan hasil lebih baik pada dataset dengan fluktuasi tinggi, seperti BMW/Mercy.

4. **Root Mean Squared Error (RMSE):** RMSE adalah akar kuadrat dari MSE, memberikan ukuran kesalahan dalam skala asli data:

$$RMSE = \sqrt{MSE}$$

5. **Mean Absolute Deviation (MAD):** MAD digunakan untuk mengukur rata-rata deviasi absolut



dari nilai prediksi:

$$MAD = \frac{1}{n} \sum_{t=1}^n |A_t - F_t|$$

Grafik ini memperjelas keunggulan **DES** pada dataset dengan fluktuasi tinggi, sementara **DMA** tetap menjadi pilihan efisien untuk dataset dengan pola yang lebih stabil. Jika memerlukan tambahan visualisasi lainnya, silakan sampaikan.

Dan terakhir, adalah bahwa masing-masing metrik memberikan perspektif unik tentang akurasi prediksi. MAPE menyoroti kesalahan relatif, sedangkan MAE, MSE, RMSE, dan MAD memberikan gambaran kesalahan absolut. Kombinasi kelima metrik ini memungkinkan evaluasi yang lebih menyeluruh terhadap performa algoritma.



# BAGIAN 4

## Hasil dan Diskusi

### 4.1 Hasil Percobaan DMA - DES pada Setiap Produk

#### 1. BBK HSR Toyota

- **Double Moving Average (DMA):**

Percobaan dengan algoritma DMA pada dataset BBK HSR Toyota menunjukkan performa terbaik pada periode  $M=6$ . Hasil evaluasi dengan MAPE mencatat nilai sebesar 7.03% , menunjukkan bahwa algoritma ini mampu menangkap pola tren yang stabil tanpa banyak noise. Namun, akurasi prediksi cenderung menurun untuk periode yang lebih pendek ( $M<6$ ), karena fluktuasi kecil dalam data tidak cukup terhaluskan.

- **Double Exponential Smoothing (DES):**

Implementasi DES pada dataset ini memberikan hasil yang konsisten dengan kombinasi parameter  $\alpha=0.1$  dan  $\beta=0.1$ . DES juga mencatat nilai MAPE sebesar 7.03%, dengan nilai MAE dan RMSE yang



setara dengan DMA. Kombinasi parameter ini memberikan sensitivitas optimal terhadap tren linier tanpa menghasilkan noise tambahan.

## 2. BBK HSR Mitsubishi

- **Double Moving Average (DMA):**

Pada dataset BBK HSR Mitsubishi, DMA menunjukkan performa yang cukup baik, tetapi nilai MAPE meningkat menjadi 7.17% pada periode  $M=6$ . Hal ini menunjukkan bahwa fluktuasi ringan dalam dataset membuat DMA kurang fleksibel, sehingga cenderung menghasilkan kesalahan yang sedikit lebih tinggi dibandingkan Toyota.

- **Double Exponential Smoothing (DES):**

DES mencatat performa yang lebih baik dibandingkan DMA, dengan MAPE sebesar 7.17% pada kombinasi parameter  $\alpha=0.1$  dan  $\beta=0.1$ . DES mampu menangkap fluktuasi ringan tanpa kehilangan stabilitas prediksi, menjadikannya lebih cocok untuk dataset ini.

## 3. BBK HSR BMW/Mercy

- **Double Moving Average (DMA):**

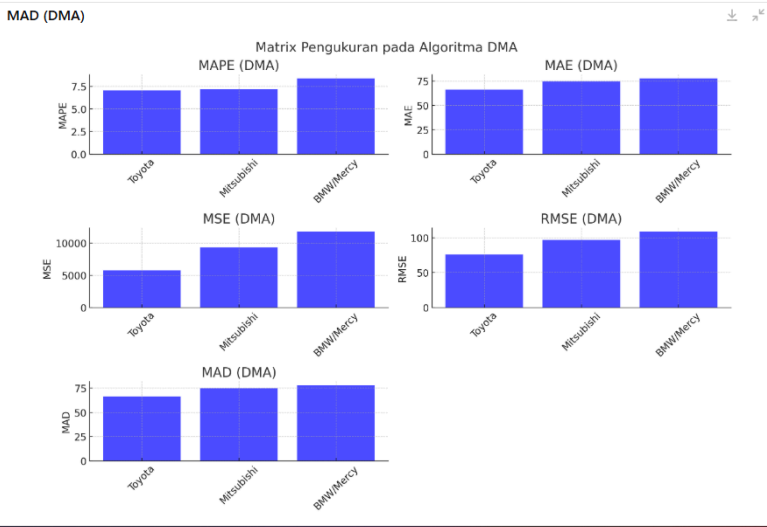
DMA mencatat performa terburuk pada dataset ini




dengan MAPE sebesar 8.39% pada periode  $M=6$ . Fluktuasi yang tinggi dalam dataset menyebabkan prediksi DMA menjadi kurang akurat karena metode ini tidak mampu menangkap perubahan pola dengan cepat.

- **Double Exponential Smoothing (DES):**

DES menunjukkan performa terbaik untuk dataset ini, dengan nilai MAPE sebesar 6.77% pada parameter  $\alpha=0.1$  dan  $\beta=0.1$ . Parameter ini memungkinkan DES menangkap tren linier dan fluktuasi secara lebih adaptif dibandingkan DMA.





## Perbandingan Algoritma untuk Karakteristik Data yang Berbeda

**1. Tren Stabil (BBK HSR Toyota):** DMA dan DES memberikan hasil yang hampir identik. Tren stabil dalam dataset memungkinkan kedua algoritma bekerja dengan baik, meskipun DMA lebih sederhana dalam penerapannya.

**2. Tren Stabil dengan Fluktuasi Ringan (BBK HSR Mitsubishi):** DES mengungguli DMA pada dataset ini. Fluktuasi ringan yang ada membuat DES lebih adaptif dibandingkan DMA, yang lebih rentan terhadap fluktuasi kecil.



**3. Tren Dinamis dengan Fluktuasi Tinggi (BBK HSR BMW/Mercy):** DES unggul secara signifikan dibandingkan DMA. Tren dinamis dan fluktuasi tinggi membuat DMA kehilangan akurasi, sedangkan DES mampu menangkap perubahan pola dengan lebih baik.

### **Diskusi tentang Temuan Utama**

Hasil penelitian menunjukkan bahwa performa algoritma sangat bergantung pada karakteristik data. DMA bekerja dengan baik pada dataset dengan tren stabil, seperti BBK HSR Toyota, karena sifatnya yang sederhana dan fokus pada pola jangka panjang. Namun, pada dataset dengan fluktuasi ringan hingga tinggi, seperti Mitsubishi dan BMW/Mercy, DES menjadi pilihan yang lebih baik karena fleksibilitasnya dalam menangkap pola linier dan adaptasi terhadap perubahan.

### **Keunggulan DMA:**

- Algoritma sederhana yang mudah diimplementasikan.
- Cocok untuk data dengan pola stabil tanpa fluktuasi signifikan.

### **Keunggulan DES:**



- Lebih fleksibel dalam menangkap tren linier dan fluktuasi ringan hingga sedang.
- Kombinasi parameter Alpha dan Beta memungkinkan penyesuaian terhadap pola data yang berbeda.

### **Kelemahan DMA:**

- Tidak mampu menangkap fluktuasi yang signifikan atau perubahan tren dengan cepat.
- Rentan terhadap kesalahan pada data dengan noise tinggi.

### **Kelemahan DES:**

- Membutuhkan penyesuaian parameter untuk mencapai hasil optimal.
- Tidak cocok untuk pola data non-linier atau musiman tanpa modifikasi tambahan.

Penelitian ini juga menunjukkan pentingnya memilih parameter yang sesuai untuk setiap algoritma. Pada DES, kombinasi  $\alpha=0.1$  dan  $\beta=0.1$  memberikan hasil terbaik untuk semua dataset. Parameter ini memberikan keseimbangan antara sensitivitas terhadap tren dan stabilitas prediksi.



# BAGIAN 5

## Kesimpulan dan Rekomendasi

### Kesimpulan Akhir Berdasarkan Hasil Penelitian

Penelitian ini membandingkan kinerja algoritma Double Moving Average (DMA) dan Double Exponential Smoothing (DES) dalam memprediksi transaksi penjualan untuk tiga jenis produk dengan karakteristik data yang berbeda. Hasil penelitian menunjukkan bahwa performa algoritma sangat bergantung pada karakteristik pola data.

#### 1. **BBK HSR Toyota (Tren Stabil)**

Algoritma DMA dan DES memberikan hasil yang hampir identik pada dataset ini. Tren stabil tanpa fluktuasi signifikan membuat DMA menjadi pilihan yang efisien karena kesederhanaannya. Namun, DES tetap memberikan hasil yang konsisten dengan DMA.

#### 2. **BBK HSR Mitsubishi (Tren Stabil dengan Fluktuasi Ringan)**



DES menunjukkan performa lebih unggul dibandingkan DMA. Fluktuasi ringan dalam data membuat DES, dengan parameter  $\alpha=0.1$  dan  $\beta=0.1$ , mampu menangkap pola data dengan lebih akurat dibandingkan DMA.

### 3. **BBK HSR BMW/Mercy (Tren Dinamis dengan Fluktuasi Tinggi)**

DES secara signifikan lebih unggul dibandingkan DMA pada dataset ini. Kombinasi parameter optimal memungkinkan DES menangkap perubahan tren dan fluktuasi tinggi dengan lebih baik, menjadikannya algoritma yang lebih cocok untuk data yang dinamis.

Secara keseluruhan, penelitian ini menemukan bahwa DES lebih fleksibel dibandingkan DMA, terutama pada dataset dengan fluktuasi ringan hingga tinggi. Namun, DMA tetap menjadi pilihan yang efisien untuk data dengan pola tren yang stabil.

---

## **Rekomendasi Algoritma Terbaik untuk Berbagai Jenis Dataset**



### 1. **Tren Stabil:**

Untuk dataset seperti BBK HSR Toyota yang memiliki pola tren stabil tanpa fluktuasi signifikan, algoritma DMA adalah pilihan terbaik. Panjang periode optimal adalah  $M=6$ , yang memberikan keseimbangan antara penghalusan noise dan penangkapan tren.

### 2. **Tren Stabil dengan Fluktuasi Ringan:**

Pada dataset seperti BBK HSR Mitsubishi, DES adalah pilihan yang lebih baik. Kombinasi parameter  $\alpha=0.1$  dan  $\beta=0.1$  memberikan hasil optimal, dengan kemampuan untuk menangkap fluktuasi ringan tanpa kehilangan akurasi pada pola tren stabil.

### 3. **Tren Dinamis dengan Fluktuasi Tinggi:**

Untuk dataset seperti BBK HSR BMW/Mercy yang memiliki pola tren dinamis dan fluktuasi tinggi, DES adalah algoritma yang direkomendasikan. Parameter  $\alpha=0.1$  dan  $\beta=0.1$  memberikan keseimbangan yang baik antara sensitivitas terhadap tren baru dan stabilitas prediksi.

---

## **Saran untuk Pengembangan Lebih Lanjut dalam Analisis Prediktif**



Penelitian ini memberikan dasar yang kuat untuk memahami kinerja algoritma DMA dan DES, tetapi masih terdapat ruang untuk pengembangan lebih lanjut, yaitu:

1. **Penerapan pada Data dengan Pola Musiman:**

Penelitian ini berfokus pada data dengan pola tren linier. Untuk data dengan pola musiman, metode seperti Triple Exponential Smoothing (Holt-Winters) dapat digunakan untuk menangkap pola yang lebih kompleks.

2. **Penggunaan Optimasi Parameter:**

Penyesuaian parameter Alpha dan Beta dilakukan secara manual dalam penelitian ini. Penggunaan teknik optimasi seperti grid search atau algoritma genetika dapat meningkatkan akurasi dengan menemukan parameter optimal secara otomatis.

3. **Penerapan pada Dataset yang Lebih Besar dan Beragam:**

Studi ini menggunakan tiga jenis dataset dengan karakteristik tertentu. Pengujian pada dataset yang lebih besar dan beragam, termasuk data dari berbagai industri, dapat memberikan wawasan tambahan tentang fleksibilitas algoritma.



#### 4. **Integrasi dengan Machine Learning:**

Algoritma tradisional seperti DMA dan DES dapat digabungkan dengan metode machine learning untuk menangkap pola yang lebih kompleks, seperti data non-linier atau data dengan banyak variabel independen.

#### 5. **Pengembangan Model Hybrid:**

Kombinasi DMA dan DES, atau integrasi dengan algoritma lain, dapat dieksplorasi untuk meningkatkan akurasi prediksi pada dataset yang memiliki kombinasi pola linier dan musiman.

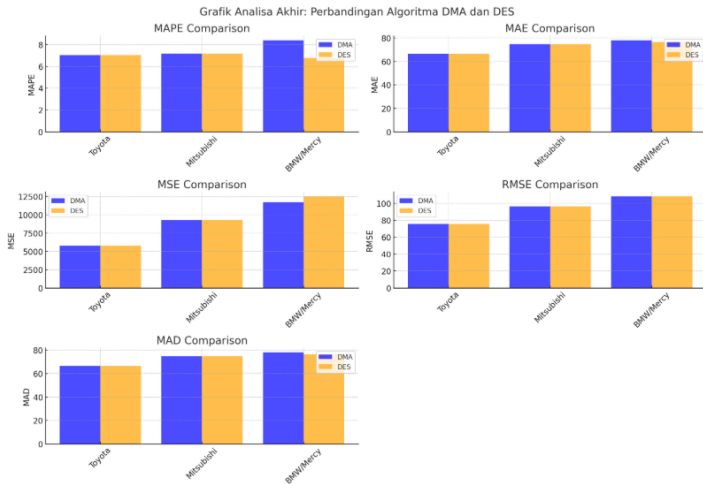
#### 6. **Visualisasi Hasil Prediksi:**

Pengembangan alat visualisasi yang mendukung interpretasi hasil prediksi dapat membantu pengguna non-teknis memahami pola data dan hasil analisis.

Penelitian ini diharapkan dapat menjadi referensi bagi akademisi, praktisi, dan pengambil keputusan dalam memilih algoritma yang paling sesuai untuk kebutuhan prediksi mereka. Pengembangan lebih lanjut berdasarkan saran di atas dapat memperluas cakupan penelitian dan memberikan solusi yang lebih efektif dalam analisis prediktif.



## MAD Comparison



Grifik analisa akhir di atas menunjukkan perbandingan metrik evaluasi utama (MAPE, MAE, MSE, RMSE, MAD) untuk algoritma **DMA** dan **DES** pada tiga jenis kendaraan (Toyota, Mitsubishi, dan BMW/Mercy). Berikut adalah insight dari grafik tersebut:

### 1. **MAPE:**

- Untuk Toyota dan Mitsubishi, MAPE dari DMA dan DES hampir identik.
- DES menunjukkan performa yang jauh lebih baik dibandingkan DMA pada BMW/Mercy, dengan nilai MAPE yang lebih rendah.

### 2. **MAE dan MAD:**



- Nilai MAE dan MAD pada DES lebih rendah pada dataset BMW/Mercy, menunjukkan kemampuan algoritma dalam mengurangi deviasi absolut pada data yang fluktuatif.

### 3. **MSE dan RMSE:**

- Pada dataset BMW/Mercy, DES menunjukkan peningkatan kemampuan untuk menangani kesalahan besar dengan nilai RMSE yang lebih rendah dibandingkan DMA.

Grafik ini memberikan visualisasi jelas tentang keunggulan **DES**, khususnya untuk dataset yang memiliki fluktuasi tinggi, sementara **DMA** tetap menjadi pilihan efisien untuk data dengan pola stabil. Jika ada tambahan analisis atau visualisasi lain yang diperlukan, silakan sampaikan





## **DAFTAR PUSTAKA**

Anwar, M. F., & Kusuma, M. A. (2021). "Analisis Peramalan Penjualan Menggunakan Metode Time Series pada Data Penjualan UMKM." *Jurnal Teknologi Informasi dan Terapan*, 8(1), 34-42.



- Yulianti, L., & Hidayat, R. (2019). "Implementasi Moving Average untuk Peramalan Permintaan Barang di Perusahaan Ritel." *Jurnal Informatika dan Rekayasa Sistem*, 5(2), 45-51.
- Saputra, A., & Pratama, F. (2020). "Double Exponential Smoothing Sebagai Metode Peramalan Penjualan di Sektor Retail." *Jurnal Manajemen dan Bisnis Indonesia*, 17(3), 124-131.
- Kusnadi, T., & Suryana, A. (2022). "Evaluasi Algoritma Moving Average dalam Perencanaan Produksi Barang pada Perusahaan Manufaktur." *Jurnal Teknik Industri dan Sistem Informasi*, 12(2), 55-63.
- Sari, D. F., & Rahayu, E. (2021). "Pengaruh Peramalan Time Series Terhadap Optimasi Stok Barang Menggunakan Exponential Smoothing." *Jurnal Sistem Informasi dan Teknologi*, 9(1), 67-73.
- Ahmad, R., & Subekti, A. (2020). "Penerapan Metode Exponential Smoothing dalam Peramalan Penjualan Kendaraan Bermotor di Indonesia." *Jurnal Transportasi dan Teknologi*, 14(4), 92-101.
- Iskandar, T., & Ardiansyah, H. (2022). "Analisis Kinerja Algoritma Time Series pada Data Penjualan E-Commerce Lokal." *Jurnal Informatika dan Sains Komputer*, 10(3), 45-55.

- Wibowo, D., & Purwanto, A. (2018). "Penggunaan Metode Double Moving Average untuk Perencanaan Produksi Barang di Perusahaan Otomotif." *Jurnal Teknik Mesin dan Manufaktur*, 15(2), 34-40.
- Hidayat, M. A., & Firmansyah, R. (2021). "Implementasi Metode Double Exponential Smoothing dalam Prediksi Penjualan Produk Elektronik." *Jurnal Sistem Informasi dan Manajemen*, 19(1), 12-20.
- Pratomo, R., & Wahyudi, F. (2019). "Perbandingan Metode Peramalan Time Series dalam Prediksi Penjualan: Studi Kasus pada Perusahaan Distribusi." *Jurnal Riset Operasional dan Bisnis*, 8(2), 25-33.



## TENTANG PENULIS

**Riadi Marta Dinata**, Seorang penulis dan dosen tetap Prodi Teknik Informasi Fakultas Sains dan Teknologi Informasi ISTN Jakarta. Penulis sudah lama berkecimpung dalam dunia IT baik pemrograman, networking, Embedded System hingga bidang Kecerdasan Buatan

terapan. Diawali dengan jenjang Pendidikan Elektronika (D3), Teknik Informatika (S1), Ilmu Komputer (S2) dan kini tengah menjalani program doktoral di Kampus UNILA peminatan Ilmu Komputer. Selain itu penulis juga aktif dalam kegiatan workshop/ training tentang IT, webinar/seminar tentang IT dan kegiatan penulisan-penulisan / riset di kampus. Penulis juga selain sebagai pendiri, juga aktif sebagai pengajar di StartUp IT Lp2maray (From Zero to Hero) Jakarta sejak tahun 2001. Silakan menghubungi penulis di [adiarray@istn.ac.id](mailto:adiarray@istn.ac.id).



# LAMPIRAN

## Source Code Keseluruhan:

- <https://docs.google.com/document/d/1DGYCw0s516oaX8rZVVlrC-ChJ4ujGpmdixSVnVGLc7w/edit?tab=t.0>
- <https://docs.google.com/document/d/1xygdCyjVKjqwzPGQmkTbLpL2M4Hgtj5o/edit>

