

Penerapan Metode Moving Average Untuk Analisis Dan Visualisasi Tren Diagnosis Penyakit Harian Data Rekam Medis *Application Of the Moving Average Method for Analysis and Visualization*

R Ramadhan Destyanto¹, Asep Id Hadiana², Gunawan Abdillah³

¹²³Teknik Informatika, Fakultas Sains dan Informatika, Universitas Jenderal Achmad Yani

¹ramadhan.destianto.y15@gmail.com, ²asep.hadiana@lecture.unjani.ac.id, ³gna@if.unjani.ac.id

Abstract

Over time, digitization in the healthcare sector has produced a large number of Electronic Medical Records (EMR) that can potentially be used for disease trend analysis. This study focuses on the application of the moving average method to analyze and visualize daily diagnosis patterns, emphasizing the comparison between Simple Moving Average (SMA) and Exponential Moving Average (EMA). These two methods are important because they can smooth out daily data fluctuations, highlight key patterns, and help detect trend changes that are relevant for real-time disease monitoring. The dataset used consists of 995 patient diagnosis transaction records from a specific observation period at TMC Tasikmalaya Hospital. The research stages included data cleaning, aggregation of daily diagnosis frequencies, transformation into time series, filtering of diseases with sufficient case numbers, and application of SMA and EMA models for data smoothing. The analysis results show that the diagnosis of "non-specific fever" consistently ranks highest in all methods, with an average value ranging from 0.2041 to 0.2050. Quantitatively, the 7-day EMA proved to be the most optimal because it was able to balance the prediction error rate and trend stability, with a Root Mean Square Error (RMSE) value of 0.1645 and a Mean Absolute Error (MAE) of 0.0714, showing higher adaptability than SMA in capturing daily changes. These findings confirm the potential of integrating EMA-7 into real-time disease monitoring systems in hospitals to support early identification of case increases and data-driven decision-making. Thus, this study highlights the important role of the moving average method in medical diagnosis trend analysis and opens up opportunities for further development in decision support systems in the health sector.

Keywords: electronic medical records, disease trends, simple moving average, exponential moving average, data visualization

Abstrak

Seiring berjalannya waktu, digitalisasi di sektor kesehatan telah menghasilkan jumlah besar *Electronic Medical Records* (EMR) yang berpotensi dimanfaatkan untuk analisis tren penyakit. Penelitian ini berfokus pada penerapan metode *moving average* untuk menganalisis dan memvisualisasikan pola diagnosis harian, dengan menekankan perbandingan antara *Simple Moving Average* (SMA) dan *Exponential Moving Average* (EMA). Kedua metode ini penting karena mampu menghaluskan fluktuasi data harian, menonjolkan pola utama, serta membantu mendeteksi perubahan tren yang relevan bagi pemantauan penyakit secara real-time. Dataset yang digunakan terdiri atas 995 catatan transaksi diagnosis pasien dari periode observasi tertentu dari rumah sakit TMC Tasikmalaya. Tahapan penelitian mencakup pembersihan data, agregasi frekuensi diagnosis harian, transformasi ke bentuk deret waktu, penyaringan penyakit dengan jumlah kasus memadai, serta penerapan model SMA dan EMA untuk proses perataan data. Hasil analisis menunjukkan bahwa diagnosis "demam tidak spesifik" menempati peringkat tertinggi secara konsisten di semua metode, dengan nilai rata-rata berkisar antara 0,2041–0,2050. Secara kuantitatif, EMA dengan rentang 7 hari terbukti paling optimal karena mampu menyeimbangkan tingkat kesalahan prediksi dan kestabilan tren, dengan nilai *Root Mean Square Error* (RMSE) sebesar 0,1645 dan *Mean Absolute Error* (MAE) sebesar 0,0714, menunjukkan adaptivitas yang lebih tinggi dibanding SMA dalam menangkap perubahan harian. Temuan ini menegaskan potensi integrasi EMA-7 ke dalam sistem pemantauan penyakit real-time di rumah sakit, guna mendukung identifikasi dini peningkatan kasus dan pengambilan keputusan berbasis data. Dengan demikian, penelitian ini memperlihatkan peran penting metode *moving average* dalam analisis tren diagnosis medis serta membuka peluang pengembangan lebih lanjut dalam sistem pendukung keputusan di sektor kesehatan.

Kata kunci: Rekam medis elektronik, tren penyakit, *simple moving average*, *exponential moving average*, visualisasi data

1. Pendahuluan

Digitalisasi di sektor kesehatan telah mendorong pemanfaatan *Electronic Medical Record* (EMR)

sebagai sistem pencatatan utama untuk menyimpan data medis pasien, termasuk diagnosis, hasil laboratorium, dan riwayat perawatan [1], [2]. Data tersebut kini menjadi aset penting bagi rumah sakit karena dapat

dimanfaatkan untuk meningkatkan mutu pelayanan dan efisiensi pengelolaan sumber daya [3]. Seiring meningkatnya jumlah kunjungan pasien, ukuran data yang dihasilkan pun semakin besar dan kompleks. Kondisi ini menuntut fasilitas pelayanan kesehatan untuk mampu mengolah dan menganalisis data EMR secara efektif agar proses pengambilan keputusan berbasis data dapat berjalan optimal [4].

Meskipun demikian, sebagian besar data EMR bersifat transaksional, di mana setiap entri merepresentasikan satu peristiwa medis. Struktur ini menyebabkan analisis tren jangka panjang sulit dilakukan secara langsung. Hal ini menimbulkan kesenjangan antara banyaknya data kesehatan yang tersedia dengan kebutuhan informasi yang dapat ditindaklanjuti untuk mendukung perencanaan dan pengambilan keputusan strategis [5]. Oleh karena itu, diperlukan pendekatan analisis yang mampu mengekstraksi pola tersembunyi dari data EMR, khususnya untuk mengidentifikasi tren penyakit yang dinamis seiring meningkatnya mobilitas masyarakat.

Pendekatan yang relevan untuk menganalisis data berurutan semacam ini adalah analisis deret waktu (*time series analysis*), yang memungkinkan identifikasi tren jangka panjang dan pola musiman [6], [7]. Dalam konteks ini, metode *moving average* seperti *Simple Moving Average* (SMA) dan *Exponential Moving Average* (EMA) sering digunakan karena kemampuannya dalam menghaluskan fluktuasi data dan menonjolkan tren utama [8], [9]. Metode SMA menghitung rata-rata aritmetika dari sejumlah titik data terbaru, sedangkan EMA memberikan bobot lebih besar pada data terbaru sehingga lebih adaptif terhadap perubahan terkini [10], [11].

Berbagai penelitian sebelumnya telah menerapkan metode *moving average* di bidang ekonomi, manufaktur, dan epidemiologi, seperti peramalan

penjualan, deteksi wabah penyakit menular, serta prediksi jumlah penderita tuberkulosis [12], [13]. Namun, penerapan metode ini dalam konteks analisis tren diagnosis penyakit berbasis EMR masih jarang dikaji. Sebagian besar penelitian terdahulu berfokus pada peramalan agregat atau data makro, bukan pada pengolahan data diagnosis pasien harian yang direkam langsung dari sistem EMR rumah sakit. Kondisi ini menunjukkan adanya *research gap* dalam penerapan metode *moving average* untuk analisis tren diagnosis penyakit harian berbasis data rekam medis elektronik.

Berdasarkan kesenjangan tersebut, penelitian ini menggunakan pendekatan berupa penerapan dan perbandingan metode SMA dan EMA dalam mengidentifikasi dan memvisualisasikan tren diagnosis penyakit harian dari data EMR rumah sakit. Dengan memanfaatkan kedua metode tersebut, penelitian ini bertujuan untuk menghaluskan fluktuasi data harian, menonjolkan tren utama yang mendasari, serta menghasilkan visualisasi yang informatif. Hasil analisis diharapkan dapat mendukung proses pengambilan keputusan strategis di fasilitas pelayanan kesehatan, khususnya dalam pemantauan penyakit secara real-time dan perencanaan sumber daya secara efisien [14][15].

2. Metode Penelitian

Bagian ini menjelaskan metode yang digunakan dalam studi untuk menganalisis dan memvisualisasikan tren harian dalam diagnosis penyakit. Proses ini meliputi pengumpulan data, pembersihan data, agregasi, transformasi ke bentuk *pivot*, penyaringan data, penerapan model rata-rata bergerak, serta analisis dan evaluasi hasil. Setiap tahap pada Gambar 1 dirancang untuk memastikan kualitas data, mengurangi fluktuasi yang tidak relevan, dan menghasilkan visualisasi yang informatif untuk mendukung pengambilan keputusan strategis di fasilitas Kesehatan.



Gambar 1. Alur kerja pengolahan data diagnosis harian menggunakan *moving average*

Sumber data yang digunakan dalam studi ini berasal dari *dataset* DetailIriUtama.csv dari rumah sakit TMC Tasikmalaya, yang berisi catatan transaksi diagnostik pasien di fasilitas kesehatan. Dataset ini terdiri dari 995 catatan yang mewakili aktivitas diagnostik yang dilakukan oleh tenaga medis selama periode pengamatan. Dataset tersebut memiliki 10 atribut (kolom) yang mewakili informasi pasien, kode diagnosis, dan prosedur medis terkait.

Dapat dilihat pada Tabel 1, dari sepuluh atribut yang tersedia, hanya beberapa yang digunakan secara langsung dalam proses analisis. Atribut Regno, KdICD, dan Diagnosis menjadi fokus utama karena menyediakan informasi dasar tentang identitas transaksi dan kode diagnosis yang akan dianalisis untuk mengidentifikasi pola tren penyakit menggunakan metode *moving average*. Sementara itu, atribut *Date* dan *Medrec* digunakan sebagai referensi tambahan untuk analisis berbasis waktu dan identifikasi pasien

yang unik, tetapi tidak digunakan secara langsung sebagai item dalam pembentukan pola asosiasi.

Tabel 1. Data Collection

No.	Nama Kolom	Tipe Data (Perkiraan)	Deskripsi
1	Regno	Teks (String)	ID unik untuk setiap kunjungan, menjadi dasar ID transaksi
2	Medrec	Teks (String)	ID unik untuk setiap pasien
3	Tanggal	Tanggal (Date)	Tanggal kunjungan pasien
4	KdICD	Teks (String)	Kode diagnosis standar ICD-10, menjadi item utama dalam transaksi
5	KdDTD	Teks (String)	Kode diagnosis internal rumah sakit
6	Diagnosa	Teks (String)	Nama atau deskripsi diagnosis dari kode ICD-10
7	KdTDK	Teks (String)	Kode tindakan medis
8	Tindakan	Teks (String)	Deskripsi tindakan medis
9	Kasus	Teks (String)	Kategori kasus (misalnya baru atau lama)
10	ValidUser	Teks (String)	Pengguna (dokter) yang memvalidasi data

Dataset yang digunakan terdiri dari 995 baris, yang kemudian dimuat ke dalam *pandas dataframe* sebagai tahap awal. Tujuannya adalah untuk meningkatkan kualitas data sehingga data menjadi lebih andal dan sesuai untuk analisis atau penggunaan lain [16].

Pertama, baris dengan nilai kosong pada kolom Tanggal dan Diagnosis dihapus, karena kedua kolom tersebut menjadi acuan utama dalam analisis dan ketidaklengkapan pada bagian ini akan menurunkan reliabilitas hasil. Kedua, dilakukan penyesuaian tipe data pada kolom tanggal agar dapat diproses dalam analisis berbasis waktu. Terakhir, kolom Diagnosis dinormalisasi dengan mengubah seluruh teks menjadi huruf kecil dan menghapus spasi berlebih. Dengan cara ini, variasi penulisan yang sebenarnya merujuk pada diagnosis yang sama, seperti “*acute abdomen*” dan “*Acute Abdomen*,” dapat digabungkan menjadi satu kategori yang konsisten.

Data transaksi yang telah dibersihkan kemudian digabungkan untuk menghitung frekuensi harian setiap diagnosis dengan mengelompokkan dataset berdasarkan kolom Tanggal dan Diagnosis. Pendekatan ini serupa dengan konsep penggabungan dalam studi permintaan energi, di mana menggabungkan beban individu yang banyak dapat mengurangi variabilitas dan menonjolkan tren keseluruhan[17]. Demikian pula, penggabungan transaksi diagnosis memungkinkan visualisasi tren penyakit kolektif di tingkat rumah sakit daripada fokus pada catatan pasien individu.

DataFrame yang telah diagregasi kemudian di *pivot* untuk membentuk matriks seri waktu, di mana setiap baris mewakili tanggal tunggal, setiap kolom mewakili diagnosis unik, dan setiap nilai sel menunjukkan jumlah kasus untuk diagnosis tersebut pada tanggal tersebut. Setelah di *pivot*, nilai yang hilang (NaN) diisi dengan nol, karena secara logis mewakili tidak adanya kasus yang tercatat pada hari yang bersangkutan.

Untuk memfokuskan analisis pada diagnosis dengan sinyal temporal yang cukup, langkah penyaringan diterapkan. Hanya diagnosis yang mencatat kasus non-nol pada setidaknya empat hari yang berbeda yang

dipertahankan. Langkah ini memastikan model diterapkan hanya pada seri waktu dengan kepadatan yang memadai, mengurangi kekosongan dalam *dataset*.

Moving Average meningkatkan kualitas data yang dianalisis dengan menekan pengaruh perubahan sementara (*noise*) dan menonjolkan tren dengan rentan waktu yang relevan untuk pemodelan[18][19]. Analisis rata-rata bergerak diterapkan pada setiap kolom diagnosis dalam dataframe yang telah diproses. Implementasi teknis dilakukan dalam lingkungan Python menggunakan perpustakaan ilmiah yang relevan.

Simple Moving Average (SMA): adalah salah satu metode yang telah terbukti berguna dalam memprediksi pola pada data deret waktu, seperti jumlah kasus penyakit[20][21]. Pada analisis ini digunakan pendekatan Simple Moving Average (SMA). Misalnya, SMA 5 dihitung dengan menjumlahkan nilai pada hari berjalan bersama empat hari sebelumnya, kemudian dibagi lima. Perhitungan ini membantu melihat tren rentan waktu sementara tanpa terlalu dipengaruhi oleh perubahan harian yang tajam. Rumus Rata-Rata Bergerak Sederhana seperti Rumus 1.

$$SMA = \frac{A_1 + A_2 + \dots + A_n}{n} \quad (1)$$

n adalah jumlah periode total, dan A_n adalah nilai pada periode n [25].

Dalam analisis ini juga digunakan *Exponential Moving Average* (EMA) untuk menghaluskan deret waktu dengan memberikan bobot lebih besar pada data terbaru [17]. Berbeda dengan SMA yang memberi bobot sama pada setiap titik data sehingga cenderung menghasilkan lag lebih besar, EMA menyesuaikan bobot secara eksponensial sehingga perubahan terkini lebih cepat tercermin dalam hasil perhitungan. Faktor pembobotan atau konstanta penyisihan dihitung berdasarkan persamaan tertentu yang menentukan seberapa besar kontribusi nilai terbaru terhadap rata-rata seperti terlihat pada Rumus 2 dan 3.

$$Multiplier = \frac{2}{N+1} \quad (2)$$

$$EMA_a = \{CP_a - EMA_{a-1}\} \times Multiplier + EMA_{a-1} \quad (3)$$

di mana:

EMA_a = Nilai EMA pada hari ke-a

CP_a = Nilai periode saat ini (misalnya, jumlah diagnosis harian)

EMA_{a-1} = Nilai EMA dari hari sebelumnya

3. Hasil dan Pembahasan

Bagian ini menyajikan hasil implementasi pendekatan yang diusulkan. Hasil mencakup pra-pemrosesan data, penerapan model *moving average*, serta visualisasi tren diagnosis penyakit. Perbandingan antara SMA dan EMA juga dilakukan.


3.1. Analisis Hasil Penerapan SMA dan EMA pada Data Diagnosis Penyakit

Pada tahap ini, visualisasi rangkaian waktu data harian untuk setiap penyakit dilakukan menggunakan metode *Simple Moving Average* (SMA) dan *Exponential Moving Average* (EMA). Tujuan utama analisis ini adalah untuk memahami pola fluktuasi setiap jenis penyakit dan mengevaluasi efektivitas metode pendekatan dalam menggambarkan tren. Rentang waktu yang digunakan untuk visualisasi ini adalah dari 1 September 2023 hingga 5 November 2023.

Tabel 2 Hasil Perbandingan Performa Model Simple dan Exponential Moving Average


Model	RMSE	MAE	MAPE (%)	R ²	Correlation
EMA-14	0.1850	0.0832	80.0702	0.2135	0.5056
EMA-3	0.1178	0.0471	45.1731	0.6813	0.8675
EMA-7	0.1645	0.0714	68.5713	0.3782	0.6661
SMA-14	0.1997	0.0897	86.0850	0.0818	0.2868
SMA-3	0.1664	0.0627	60.0136	0.3640	0.6027

Berdasarkan hasil pengujian model peramalan yang disajikan pada Tabel 2, dapat dilihat bahwa model EMA-3 memberikan performa terbaik dibandingkan dengan model lainnya. Nilai RMSE sebesar 0,1178 dan MAE sebesar 0,0471 menunjukkan tingkat kesalahan prediksi paling rendah, sementara MAPE sebesar 45,17% menunjukkan bahwa rata-rata kesalahan relatif masih dalam batas moderat untuk data dengan fluktuasi tinggi. Nilai R² sebesar 0,6813 dan korelasi sebesar 0,8675 juga menandakan bahwa model ini memiliki kemampuan yang baik dalam menjelaskan variasi data aktual serta hubungan yang kuat antara nilai aktual dan hasil prediksi. Sebaliknya, model dengan periode perataan yang lebih panjang seperti EMA-14 dan SMA-14 menunjukkan peningkatan error dan penurunan nilai R², menandakan penurunan akurasi prediksi.




Gambar 2. Heatmap Perbandingan Multi-Metrik

Selanjutnya, Gambar 2 memperlihatkan hasil visualisasi heatmap perbandingan model peramalan dengan mempertimbangkan enam metrik evaluasi, yaitu RMSE, MAE, R², korelasi, trend accuracy, dan smoothness. Hasil visualisasi memperkuat temuan sebelumnya, di mana EMA-3 memiliki performa terbaik secara keseluruhan dengan nilai kesalahan terendah dan korelasi tertinggi (R² = 0,681; korelasi = 0,868). Namun demikian, dari sisi trend accuracy, model SMA menunjukkan hasil yang lebih tinggi (sekitar 90%) dibandingkan EMA (sekitar 17%), yang mengindikasikan kemampuannya dalam mengikuti arah tren jangka panjang secara lebih stabil. Berdasarkan hal tersebut, dapat disimpulkan bahwa EMA dengan periode pendek lebih efektif untuk mendeteksi perubahan jangka pendek secara presisi, sedangkan SMA dengan periode lebih panjang lebih sesuai untuk analisis tren jangka panjang yang lebih halus dan stabil.




Gambar 3. Visualisasi Moving average “Acute Abdomen”

Data diagnosis abdomen akut pada Gambar 3 menunjukkan distribusi biner, dengan dominasi nilai nol dan beberapa puncak nilai satu pada hari-hari tertentu. Hal ini menunjukkan bahwa kejadian abdomen akut relatif jarang terjadi. Seperti yang ditunjukkan pada Gambar 3, SMA dengan rentang waktu pendek (3 hari) menghasilkan grafik yang sangat fluktuatif dan tidak stabil, sementara SMA 14 hari memberikan gambaran yang jauh lebih halus tetapi lambat dalam merespons perubahan. Sebaliknya, EMA dengan rentang 7 hari mampu menangkap perubahan secara lebih adaptif tanpa kehilangan informasi tren. Oleh karena itu, EMA dianggap lebih cocok untuk mendeteksi peningkatan mendadak yang mungkin terjadi dalam kasus abdomen akut.




Gambar 4. Visualisasi Moving average "Pneumonia Unspecified"

Pada Gambar 4 pola diagnosis pneumonia yang tidak spesifik menunjukkan frekuensi kejadian yang lebih tinggi dibandingkan dengan abdomen akut, dengan jumlah hari berturut-turut yang menunjukkan nilai diagnostik sebesar satu. Seperti yang ditunjukkan pada Gambar 4, SMA 14 hari menggambarkan tren yang stabil dan cocok untuk memantau perkembangan dalam periode panjang. EMA 7 hari menunjukkan keunggulan dalam menangkap variasi harian yang lebih halus dan mampu mengindikasikan potensi peningkatan kasus lebih cepat daripada SMA 14 hari. Hal ini membuat EMA lebih cocok untuk pemantauan penyakit secara *real-time*.



Gambar 5. Visualisasi Moving average "Typhoid Fever"

Pada Gambar 5 diagnosis demam tifoid memiliki karakteristik yang mirip dengan abdomen akut, yaitu frekuensi kejadian yang rendah dengan pola fluktuasi yang tinggi. Seperti yang ditunjukkan pada Gambar 5, SMA 3 hari menghasilkan grafik dengan perubahan yang sangat tajam dan sulit diinterpretasikan, sementara SMA 14 hari terlalu lambat dalam menangkap perubahan. EMA 7 hari sekali lagi menunjukkan kinerja terbaik dalam menyeimbangkan sensitivitas terhadap perubahan dan kelancaran kurva, sehingga cocok untuk mendeteksi lonjakan yang jarang terjadi namun signifikan.




Gambar 6. Visualisasi Moving average "Asthma Unspecified"

Gambar 6 menunjukkan ada yang berbeda dengan tiga penyakit sebelumnya, asma yang tidak spesifik menunjukkan pola diagnosis yang lebih aktif dan teratur. Terdapat tren musiman atau periodik, ditandai dengan beberapa puncak periodik sepanjang periode pengamatan. Seperti yang ditunjukkan pada Gambar 5, baik SMA 3 hari maupun EMA 7 hari mampu

mengikuti perubahan dengan cukup baik. EMA 7 hari masih dianggap lebih unggul karena memberikan kurva yang lebih halus namun responsif, sementara SMA 14 hari terlalu menghaluskan pola periodik yang sebenarnya penting untuk analisis lebih lanjut.

3.2. Perbandingan dan Implikasinya



Gambar 7. lima penyakit teratas berdasarkan nilai rata-rata menggunakan SMA dan EMA

Visualisasi pada Gambar 7 menampilkan lima jenis penyakit dengan nilai rata-rata tertinggi berdasarkan penerapan metode penyisihan *Simple Moving Average* (SMA) dan *Exponential Moving Average* (EMA). Metode penyisihan ini diterapkan pada data harian yang dikumpulkan antara 1 September 2023 dan 5 November 2023. Gambar tersebut menunjukkan bahwa demam tanpa spesifikasi secara konsisten memiliki nilai rata-rata tertinggi dibandingkan dengan penyakit lain, baik dalam metode SMA 3 (0,2041), SMA 14 (0,2046), maupun EMA 7 (0,2050). Hal ini menunjukkan bahwa demam adalah kondisi yang paling sering dilaporkan selama periode pengamatan, dan distribusinya relatif stabil meskipun menggunakan metode pendekatan yang berbeda.

Penyakit lain yang juga masuk dalam lima besar meliputi: Nyeri perut tidak spesifik, Gastritis tidak spesifik, Perut akut, dan Diare gastroenteritis diduga asal infeksi. Nilai rata-rata untuk masing-masing penyakit ini tidak menunjukkan perbedaan signifikan antara metode pendekatan, menunjukkan bahwa pola distribusi kasus relatif konsisten meskipun menggunakan pendekatan pendekatan yang berbeda.

Secara umum, hasil ini menunjukkan bahwa metode SMA dan EMA sama efektifnya dalam memberikan gambaran tren makro dominasi penyakit, terutama saat digunakan untuk melihat distribusi penyakit dalam rentan waktu sedang. Visualisasi *heatmap* seperti ini juga membantu dalam mengidentifikasi penyakit yang memerlukan perhatian lebih lanjut dari perspektif kebijakan kesehatan masyarakat.

Berdasarkan hasil rata-rata pendekatan Tabel 3, demam tanpa spesifikasi secara konsisten menduduki peringkat pertama di semua metode, dengan nilai berkisar antara 0,2041 hingga 0,2050, menunjukkan bahwa demam merupakan diagnosis yang paling sering terjadi dan

tetap relatif stabil sepanjang periode pengamatan. Nyeri perut tidak spesifik dan gastritis tidak spesifik juga menunjukkan nilai rata-rata tinggi dengan perbedaan minimal antar metode, menunjukkan bahwa distribusi kasusnya konsisten terlepas dari teknik pendekatan yang digunakan.

Tabel 3. Perbandingan nilai SMA dan EMA pada sepuluh diagnosis penyakit teratas.

No	Disease	SMA 3 Mean	SMA 14 Mean	EMA 7 Mean
1	Fever unspecified	0.2041	0.2046	0.2050
2	Unspecified abdominal pain	0.0719	0.0721	0.0718
3	Gastritis unspecified	0.0557	0.0545	0.0556
4	Acute abdomen	0.0486	0.0489	0.0484
5	Diarrhoea gastroenteritis presumed infectious origin	0.0466	0.0471	0.0465
6	Unspecified injury head	0.0142	0.0143	0.0141
7	Unspecified renal colic	0.0263	0.0266	0.0263
8	Typhoid fever	0.0061	0.0061	0.0061
9	Pneumonia unspecified	0.0081	0.0082	0.0081
10	Asthma unspecified	0.0044	0.0042	0.0043

Untuk penyakit dengan pola perubahan yang tajam, seperti abdomen akut dan demam tifoid, perbedaan antara metode menjadi lebih jelas. EMA 7 menunjukkan adaptabilitas yang lebih besar terhadap perubahan terbaru dibandingkan SMA 14, sambil tetap mempertahankan kelancaran yang cukup untuk interpretasi visual yang jelas. Karakteristik ini membuat EMA 7 lebih cocok untuk mendeteksi peningkatan jumlah kasus secara cepat tanpa kehilangan konteks tren keseluruhan.

Di sisi lain, penyakit dengan frekuensi diagnosis rendah dan sifat tidak teratur, seperti asma yang tidak spesifik dan pneumonia yang tidak spesifik, menghasilkan nilai rata-rata yang hampir identik di semua tiga metode. Hal ini terutama disebabkan oleh kelangkaan data, yang mengurangi dampak perbedaan penimbangan dalam perhitungan SMA dan EMA. Namun, EMA 7 tetap sedikit lebih responsif daripada SMA 14 dalam menangkap perubahan tidak teratur ini.

Secara keseluruhan, SMA 3 memberikan respons tercepat tetapi menghasilkan tren yang lebih berubah-ubah, SMA 14 efektif untuk mengidentifikasi perkembangan dalam periode panjang tetapi kurang responsif terhadap lonjakan mendadak, sementara EMA 7 menawarkan keseimbangan optimal antara sensitivitas dan kelancaran. Dengan memberikan bobot lebih besar pada data terbaru, EMA 7 mampu menangkap pergeseran tren yang halus dengan lebih akurat dan menampilkannya secara jelas dalam visualisasi *real-time*. Misalnya, dalam kasus seperti asma dan pneumonia, EMA 7 menyoroti peningkatan lebih cepat daripada SMA, memungkinkan pengambilan keputusan yang lebih cepat dan terinformasi. Oleh karena itu, EMA 7

direkomendasikan untuk diintegrasikan ke dalam sistem pemantauan penyakit *real-time* di rumah sakit untuk mendukung deteksi dini dan respons kebijakan yang tepat waktu.

4. Kesimpulan

Penelitian ini membuktikan bahwa metode Exponential Moving Average (EMA) dengan rentang 7 hari memberikan keseimbangan terbaik antara responsivitas terhadap perubahan harian dan kestabilan tren diagnosis, dibandingkan dengan Simple Moving Average (SMA). Hasil pengujian menunjukkan bahwa meskipun EMA-3 memiliki performa statistik paling tinggi, EMA-7 lebih representatif dan stabil untuk kebutuhan pemantauan penyakit secara *real-time* di fasilitas kesehatan. Dengan demikian, EMA-7 dapat diandalkan sebagai pendekatan adaptif dalam sistem deteksi dini berbasis Electronic Medical Records (EMR).

Secara ilmiah, penelitian ini berkontribusi dalam memperkuat bukti empiris bahwa metode time series smoothing seperti EMA dapat digunakan secara efektif dalam analisis tren diagnosis medis berbasis data harian. Implementasi metode ini berpotensi meningkatkan efisiensi sistem pemantauan dan mendukung pengambilan keputusan berbasis data di rumah sakit.

Keterbatasan penelitian ini terletak pada ukuran dataset yang terbatas dan konteks pengamatan dari satu institusi kesehatan, sehingga generalisasi hasil masih perlu diuji lebih lanjut. Penelitian mendatang disarankan untuk memperluas cakupan dataset, menerapkan kombinasi metode moving average dengan model pembelajaran mesin, serta menguji penerapannya dalam sistem informasi klinis *real-time*. Bagi praktisi dan pengembang sistem, hasil ini dapat menjadi dasar perancangan modul analisis tren diagnosis yang lebih responsif dan adaptif di lingkungan pelayanan kesehatan.

Ucapan Terimakasih

Penulis ingin mengucapkan terima kasih kepada manajemen dan staf fasilitas kesehatan yang berpartisipasi atas akses yang diberikan terhadap *dataset* catatan medis anonim yang digunakan dalam studi ini.

Daftar Rujukan

- [1] M. J. Kim, J. Kang, M. Chu, H. Min, and S. Kim, "Use of electronic medical records in simulated nursing education and its educational outcomes: A scoping review," *Clin. Simul. Nurs.*, vol. 101, p. 101703, 2025, doi: 10.1016/j.ecns.2025.101703.
- [2] M. Z. A. Rustam, N. Amalia, and M. A. Riestiyowati, "Analisis Prediksi Kunjungan Pasien Dengan Metode Autoregressive Integrated Moving Average di Rumah Sakit Ibu dan Anak Putri Surabaya," *J. Manaj. Kesehat. Yayasan*

- RS.Dr. Soetomo, vol. 8, no. 1, p. 110, 2022, doi: 10.29241/jmk.v8i1.929.
- [3] S. Verkijk and P. Vossen, "Creating, anonymizing and evaluating the first medical language model pre-trained on Dutch Electronic Health Records: MedRoBERTa.nl," *Artif. Intell. Med.*, vol. 167, no. April 2024, p. 103148, 2025, doi: 10.1016/j.artmed.2025.103148.
- [4] S. Akter, Z. Liu, E. J. Simoes, and P. Rao, "Using machine learning and electronic health record (EHR) data for the early prediction of Alzheimer's Disease and Related Dementias," *J. Prev. Alzheimer's Dis.*, vol. 12, no. 7, p. 100169, 2025, doi: 10.1016/j.tjpad.2025.100169.
- [5] È. M. Roy, I. Georgieva, L. Fradet, L. Kaewkitipong, and M. J. Guittou, "Consenting to share data from electronic health records to research deposits: Constraints, obstacles, and proxy," *Acta Psychol. (Amst.)*, vol. 258, no. June, 2025, doi: 10.1016/j.actpsy.2025.105176.
- [6] S. Alahmari *et al.*, "A decentralized and privacy-preserving framework for electronic health records using blockchain," *Alexandria Eng. J.*, vol. 126, no. March, pp. 196–203, 2025, doi: 10.1016/j.aej.2025.04.069.
- [7] Q. Chen, J. Peng, B. Song, Y. Zhou, and R. Ji, "Graph-empowered Text-to-SQL generation on Electronic Medical Records," *Pattern Recognit.*, vol. 169, no. December 2024, p. 111800, 2026, doi: 10.1016/j.patcog.2025.111800.
- [8] A. Martinez, C. Molina, and D. Subauste, "Electronic medical records management in health organizations using a technology architecture based on blockchain," *2020 Ieee Andescon, Andescon 2020*, 2020, doi: 10.1109/ANDESCON50619.2020.9271998.
- [9] P. Irwin *et al.*, "Lesson learned from practice: Informing how to teach the use of simulated electronic medical records to nursing students," *Clin. Simul. Nurs.*, vol. 101, p. 101713, 2025, doi: 10.1016/j.ecns.2025.101713.
- [10] E. Nur Cahyo and E. Susanti*, "Analisis Time Series Untuk Deep Learning Dan Prediksi Data Spasial Seismik: Studi Literatur," *J. Teknol.*, vol. 15, no. 2, pp. 124–136, 2023, doi: 10.34151/jurtek.v15i2.3581.
- [11] D. Novanda and R. Hidayati, "Prediction of The Number of Pulmonary Tuberculosis Disease Using The Moving Average Forecasting Method And Time Series Decomposition," *Antivirus J. Ilm. Tek. Inform.*, vol. 18, no. 1, pp. 37–45, 2024, doi: 10.35457/antivirus.v18i1.3468.
- [12] L. Sarifah, S. Kamilah, and S. Khotijah, "Penerapan Metode Single Moving Average Dalam Memprediksi Jumlah Penduduk Miskin Pada Perencanaan Pembangunan Daerah Kabupaten Pamekasan," *Zeta - Math J.*, vol. 8, no. 2, pp. 47–54, 2023, doi: 10.31102/zeta.2023.8.2.47-54.
- [13] O. Chantarakasemchit, T. N. Bangkok, S. Nuchitprasitchai, T. N. Bangkok, Y. Nilsiam, and T. N. Bangkok, "Forex Rates Prediction on EUR / USD with Simple Moving Average Technique and Financial Factors," pp. 771–774, 2020.
- [14] J. Wang and S. Zhang, "An improved deep learning approach based on exponential moving average algorithm for atrial fibrillation signals identification," *Neurocomputing*, vol. 513, pp. 127–136, 2022, doi: 10.1016/j.neucom.2022.09.079.
- [15] F. R. Kharisma, Khoirudin, and D. A. Diartono, "Automated Forex Trading Using Exponential Moving Average Method," *1st Int. Conf. Technol. Eng. Comput. Appl. Trends Technol. Dev. Era Soc. 5.0, ICTECA 2023*, pp. 1–5, 2023, doi: 10.1109/ICTECA60133.2023.10490520.
- [16] F. Zou, "Research on data cleaning in big data environment," *Proc. - 2022 Int. Conf. Cloud Comput. Big Data Internet Things, 3CBIT 2022*, pp. 145–148, 2022, doi: 10.1109/3CBIT57391.2022.00037.
- [17] M. W. Jack and M. M. Bandi, "Extreme value statistics of peak residential electricity demand: Effect of aggregation and moving-average smoothing," *Sustain. Energy, Grids Networks*, vol. 42, no. July 2024, p. 101674, 2025, doi: 10.1016/j.segan.2025.101674.
- [18] X. P. Zhou, X. K. Yuan, and D. Yang, "Prediction of landslide failure time based on moving average convergence and divergence coupling with Bayesian updating method," *Eng. Geol.*, vol. 343, no. October, p. 107781, 2024, doi: 10.1016/j.enggeo.2024.107781.
- [19] A. R. Mohammed, K. S. Hassan, and M. A. M. Abdel-Aal, "Moving Average Smoothing for Gregory-Newton Interpolation: A Novel Approach for Short-Term Demand Forecasting," *IFAC-PapersOnLine*, vol. 55, no. 10, pp. 749–754, 2022, doi: 10.1016/j.ifacol.2022.09.499.
- [20] S. A. D. Darmawan and K. Karmilasari, "Prediksi Jumlah Kasus Penyakit di Jawa Timur Memanfaatkan Metode Simple Moving Average," *J. Teknol. Sist. Inf. dan Apl.*, vol. 7, no. 2, pp. 770–778, 2024, doi: 10.32493/jtsi.v7i2.38653.
- [21] L. Tomov, L. Chervenkov, D. G. Miteva, H. Batselova, and T. Velikova, "Applications of time series analysis in epidemiology: Literature review and our experience during COVID-19 pandemic," *World J. Clin. Cases*, vol. 11, no. 29, pp. 6974–6983, 2023, doi: 10.12998/wjcc.v11i29.6974.