

Clustering and Forecasting Implementation for Medical Consumables Stock Recommendation

Fahri Setia Darma^{1*}, Tedy Setiadi^{2**}

* Informatika, Universitas Ahmad Dahlan, Indonesia
fahri2100018002@webmail.uad.ac.id¹, tedy.setiadi@tif.uad.ac.id²

Article Info

Article history:

Received 2025-06-02

Revised 2025-07-11

Accepted 2025-07-19

Keyword:

*Agglomerative Hierarchical Clustering,
Medical Consumables,
Recommendations,
Single Exponential Smoothing.*

ABSTRACT

Managing medical consumables (BMHP) in hospitals can be tricky because the demand often changes unpredictably. This study aims to help hospitals manage their BMHP stocks better by using two techniques: forecasting with Single Exponential Smoothing (SES) and grouping items using Agglomerative Hierarchical Clustering (AHC). SES is used to predict future needs based on previous usage, while AHC groups similar items based on how they're used, which helps make the predictions more accurate. Before applying clustering, the prediction error was quite high, with a MAPE of 61.77% and an MAE of 18,769.80. After clustering, these numbers dropped to 10.06% and 3,987.45, showing a significant improvement. The clustering itself was strong, with a Silhouette Coefficient of 0.727, meaning the item groups made sense. Each group of items got different stock suggestions. Items with high and unstable demand were advised to keep extra safety stock. Items with uncertain patterns needed a more flexible buffer stock. For items with stable use, average trends over the last few months were enough to guide stock planning. This approach helps hospitals avoid both overstock and stockouts by giving more accurate and tailored recommendations. Although this study only used data from one hospital, the results show that combining SES and AHC can make stock management smarter and more efficient.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Rumah Sakit Hidayah Kabupaten Boyolali menghadapi tantangan dalam pengelolaan Bahan Medis Habis Pakai (BMHP), yang merupakan komponen kritis dalam pelayanan kesehatan. Menurut Peraturan Menteri Kesehatan No. 72 Tahun 2016, BMHP didefinisikan sebagai alat kesehatan sekali pakai, seperti jarum suntik, betadine, dan kapas. Keberadaan BMHP sangat menentukan efektivitas pelayanan dan pengobatan pasien, sehingga pengelolaannya memerlukan perhatian khusus.

Permasalahan utama yang dihadapi rumah sakit tersebut adalah ketidakmampuan dalam mengidentifikasi pola penggunaan BMHP, mengakibatkan estimasi kebutuhan yang tidak konsisten. Kurangnya pembagian BMHP berdasarkan intensitas penggunaan menyebabkan semua jenis diperlakukan sama dalam perencanaan stok, tanpa mempertimbangkan perbedaan kebutuhan. Sistem yang ada

juga bersifat reaktif, di mana pembelian BMHP hanya dilakukan saat stok menipis, tanpa perencanaan matang berdasarkan analisis kebutuhan mendetail. Ketidakstabilan permintaan historis, ditandai dengan lonjakan penggunaan yang sulit diprediksi, memperburuk situasi ini. Hal ini mengakibatkan dua masalah utama yakni *overstock* (persediaan berlebihan yang tidak efisien) dan *stockout* (kekurangan stok saat dibutuhkan), yang mengancam kelancaran operasi medis dan pelayanan Kesehatan

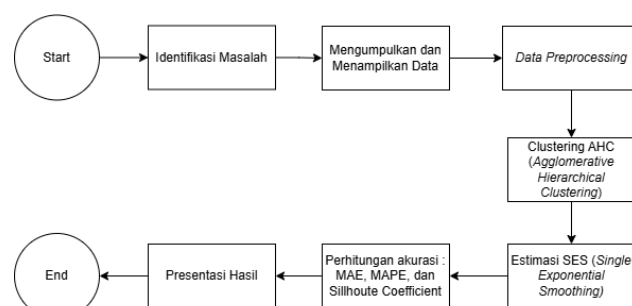
Forecasting menjadi aspek penting dalam pengelolaan persediaan BMHP, karena memungkinkan prediksi kebutuhan masa depan berdasarkan data historis. *Forecasting* adalah metode untuk memproyeksikan kejadian di masa depan, membantu mengatur pembelian dan stok secara efisien, serta menghindari kekurangan atau kelebihan persediaan [1]. Bagi Rumah Sakit Hidayah, kemampuan meramalkan kebutuhan BMHP secara akurat sangat penting untuk memastikan ketersediaan layanan kesehatan yang optimal.

Penelitian ini dengan menggabungkan model *forecasting* dengan mengintegrasikan model klasterisasi pada proses *forecasting* untuk meningkatkan akurasi prediksi [2]. Beberapa penelitian terdahulu telah menerapkan penggabungan antara *forecasting* dan *clustering*. Misalnya, penelitian oleh krisna dan Daniel (2021) Integrasi Metode *Agglomerative Hierarchical Clustering* dan *Backpropagation* Pada penelitian ini menerapkan model *forecasting* yang dimodifikasi oleh clustering untuk memperbaiki kualitas sistem peramalan sebelumnya [2]. Hasil penelitian menyatakan bahwa hasil MAPE yang didapat lebih baik jika menggunakan penerapan *clustering* pada proses peramalannya. Penelitian lain oleh Ali, Ade, dan Irfan (2023) Analisis Klasterisasi Untuk Prediksi Jumlah Kasus DBD Berdasarkan Jenis Kelamin dan Kabupaten/Kota Di Jawa Barat, penelitian ini menggabungkan peramalan dan *clustering*, dalam hal ini *clustering* digunakan untuk mengelompokkan daerah berdasarkan tingkat kasus, kemudian peramalan digunakan untuk meramalkan jumlah penyebaran DBD [3]. Hasil penelitian menunjukkan nilai k terbaik adalah 3 dengan rata-rata *davies bouldin index* sebesar 0.71 dengan menunjukkan informasi dominasi kasus. Penelitian lain oleh Diyah, Dyah, Susi, dan Herlin (2022) Clustering and Forecasting of Covid-19 Data in Indonesia, penelitian ini menggunakan penggabungan peramalan dan clustering, dalam hal ini clustering digunakan untuk mengelompokkan daerah berdasarkan jumlah kasus covid-19 kemudian peramalan digunakan untuk meramalkan jumlah kasus covid-19 berdasarkan masing-masing *cluster* [4]. Hasil dari penelitian ini menunjukkan bahwa penerapan kedua metode ini menghasilkan peramalan berdasarkan *cluster* yang cenderung konstan.

Dengan pengembangan metode *forecasting* yang dimodifikasi, diharapkan kualitas *forecasting* di Rumah Sakit Hidayah dapat ditingkatkan dan memberikan rekomendasi manajemen pengelolaan BMHP, memungkinkan rumah sakit menghadapi ketidakstabilan permintaan dengan lebih baik. Kombinasi SES dan AHC diharapkan meningkatkan efisiensi pengelolaan stok, dan memastikan ketersediaan BMHP yang optimal. Penelitian ini bertujuan meningkatkan kualitas manajemen persediaan BMHP dan pelayanan kesehatan di Rumah Sakit Hidayah Kabupaten Boyolali. Beberapa penelitian terdahulu telah menggabungkan metode peramalan dan klasterisasi dalam berbagai konteks, penelitian ini tidak hanya berfokus pada peningkatan akurasi peramalan saja melainkan menambahkan rekomendasi dalam pengelolaan manajemen yang bersifat adaptif. Dengan pendekatan ini manajemen BMHP diharapkan menjadi lebih adaptif, efisien, dan *responsive* terhadap perubahan kebutuhan.

II. METODE

Penelitian ini dilakukn dengan beberapa tahapan yang telah disusun untuk memastikan bahwa seluruh proses penelitian berjalan sesuai dengan target yang telah ditentukan. Alur penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

A. Identifikasi Masalah

Tahapan ini meliputi proses pengenalan, penemuan, pencarian, dan pengumpulan masalah dalam penelitian. Proses ini merupakan langkah awal yang bersifat krusial untuk memungkinkan pemahaman dan perumusan yang tepat terhadap masalah yang dihadapi.

B. Mengumpulkan dan Menampilkan Data

Dalam proses penelitian, fase ini berisi tentang pengumpulan dan observasi dari data yang telah ada dengan mengidentifikasi informasi. Data yang digunakan adalah data penggunaan BMHP selama 12 bulan pada tahun 2023.

C. Data Preprocessing

Pada tahapan ini dilakukan pengolahan data, di mana data dipilih, digabungkan, dan dibersihkan dari noise, redundansi, inkonsistensi, atau ketidakrelevanannya. Hal ini bertujuan agar data dapat dimanfaatkan secara optimal dan menghasilkan hasil yang akurat. Dalam konteks ini, data yang digunakan adalah penggunaan BMHP selama 12 bulan pada tahun 2023 digabungkan menjadi satu.

D. Clustering AHC (Agglomerative Hierarchical Clustering)

Proses pengelompokan objek ke dalam kluster dimulai dengan mengelompokkan setiap objek ke dalam kluster-kluster kecil, kemudian menggabungkan dua kluster yang paling mirip menjadi satu kluster. Proses ini terus diulang, dengan setiap iterasi menggabungkan kluster-kluster yang paling mirip, hingga akhirnya semua objek tergabung dalam satu kluster besar. Dalam proses ini hubungan hierarkis antar kluster terbentuk, divisualisasikan dalam bentuk dendrogram yang menunjukkan bagaimana kluster-kluster bergabung pada setiap langkah.

1) Clustering

Clustering adalah teknik analisis data yang bertujuan untuk mengelompokkan data yang sejenis ke dalam satu kelompok dan data yang berbeda ke kelompok lain. Terdapat berbagai pendekatan yang sering digunakan dalam pengembangan teknik *clustering*. Pendekatan utama dalam *clustering* yakni pendekatan hirarki dan pendekatan partisi. Pendekatan hirarki merupakan pendekatan dengan mengelompokkan data serupa ke dalam hirarki yang berdekatan, biasanya divisualisasikan

dalam bentuk dendrogram. Sedangkan pendekatan partisi mengklasifikasikan data dengan membaginya ke dalam kluster yang sudah ada, juga dikenal sebagai pemetaan otomatis (*Self-Organized Map*).

2) Agglomerative Hierarchical Clustering

Agglomerative Hierarchical Clustering merupakan metode dalam analisis kluster yang bertujuan untuk mengelompokkan data ke dalam kluster-kluster hierarkis. Proses ini dimulai dengan menganggap setiap data sebagai kluster tersendiri, kemudian secara bertahap menggabungkan kluster-kluster yang memiliki kesamaan tertinggi berdasarkan metrik atau jarak tertentu. Awalnya, jarak antara setiap pasangan data diukur, lalu dua kluster dengan jarak terdekat digabungkan menjadi satu kluster baru. Proses ini terus berlanjut dengan menggabungkan kluster-kluster yang semakin besar sampai semua data tergabung dalam satu kluster utama. Selama proses ini, terbentuk struktur hirarkis yang menggambarkan hubungan antar kluster, biasanya ditampilkan dalam bentuk pohon dendrogram atau grafik [5].

Salah satu keunggulan metode ini adalah fleksibilitasnya dalam pemilihan metrik atau jarak untuk mengukur kesamaan antar data. Metrik ini bisa berupa jarak Euclidean, jarak Manhattan, atau jarak Mahalanobis, tergantung pada karakteristik data dan tujuan analisis. Selain itu, penggunaan AHC bisa dikendalikan dengan menentukan jumlah kluster yang diinginkan atau dengan menggunakan kriteria pemotongan (*cut-off*) untuk menghentikan proses penggabungan kluster. Jarak antara dua kluster dapat dihitung menggunakan rumus jarak Euclidean atau jarak Manhattan sebagai berikut :

Rumus Jarak Euclidean :

$$d(x,y) = \sqrt{\sum_{i=1}^n |x_i - y_i|^2} \quad (1)$$

Keterangan :

- $d(x,y)$: kriteria
- x_i : nilai data latih
- y_i : nilai data uji

Singe Linked dalam AHC merupakan metode pengclusteran yang dilakukan dengan perhitungan jarak terdekat antara dua objek, berdasarkan matriks jarak Euclidean. Proses ini dilakukan secara berulang [2], sebagaimana rumus dari *single linked* sebagai berikut:

Rumus AHC Single Linked :

$$d_{xy} = \min\{d_{xy}\}, d_{xy} \in D \quad (2)$$

Keterangan :

- d_{xy} : jarak antar dua kluster
- $\min\{d_{xy}\}$: jarak minimum antar dua kluster
- D : Himpunan semua jarak

E. Estimasi SES (Single Exponential Smoothing)

Proses *forecasting* dilakukan untuk menghasilkan data peramalan. Dalam penelitian ini, metode *Single Exponential Smoothing* digunakan untuk proses *forecasting*. Metode ini dapat menghasilkan hasil yang konsisten dan efektif.

1) Forecasting

Forecasting adalah teknik yang digunakan untuk memprediksi data di masa depan berdasarkan data masa lampau. *Forecasting* juga dapat dianggap sebagai ilmu yang memproyeksikan kejadian mendatang menggunakan informasi historis [6]. Untuk melakukan proses *forecasting*, data dari masa lalu dikumpulkan dan dianalisis dengan metode tertentu. Data ini kemudian dihubungkan dengan perjalanan waktu, sehingga hasil analisis dapat memprediksi kejadian di masa depan [7].

Forecasting diperlukan untuk mengatasi kesenjangan waktu antara kesadaran akan perlunya kebijakan baru dan pelaksanaannya. Semakin panjang jeda waktu ini, semakin penting peran *forecasting*. Proses ini membantu menentukan kapan suatu peristiwa mungkin terjadi sehingga dapat diantisipasi sebelumnya. Berdasarkan rentang waktu, *forecasting* dibagi menjadi tiga kategori, diantaranya : jangka panjang (2-10 tahun), jangka menengah (1-24 bulan), dan jangka pendek (1-5 minggu) [8]. Ada dua kelompok metode yang digunakan untuk melakukan proses *forecasting*, yaitu metode kualitatif dan metode kuantitatif [9]. Kedua kelompok tersebut memiliki hasil dengan pendekatan kuantitatif, tetapi hanya prosesnya yang berbeda. Metode kuantitatif menggunakan model matematis untuk memproyeksikan data masa lalu dan membuat prediksi tentang masa depan. Di sisi lain, metode kualitatif mengandalkan pertimbangan manusia berdasarkan pengalaman mereka. Umumnya, peramalan banyak menggunakan data time series untuk memprediksi data di masa mendatang [8]. Data time series dianggap sebagai gambaran dari nilai-nilai variabel acak yang diamati pada interval waktu yang sama dan dalam periode yang spesifik [10].

2) Single Exponential Smoothing

Single Exponential Smoothing merupakan salah satu metode *forecasting* yang menggunakan konstanta pemulusan, sehingga menghasilkan data baru dengan bobot yang lebih besar [8]. Parameter pemulusan tersebut dikenal sebagai α [11], dengan rentang nilai $0 < \alpha < 1$. Dengan adanya konstanta pemulusan ini hasil peramalan memiliki bobot yang lebih besar sehingga tingkat persentase kesalahan menjadi kecil. Dengan kata lain, data hasil *forecasting* akan lebih akurat [9]. *Single exponential smoothing* memiliki beberapa karakteristik diantaranya yakni, dalam mengolah data baru model ini hanya memerlukan sedikit data lama. Metode ini menganggap bahwa data tetap tidak menunjukkan tren atau pola, serta data bergerak di sekitar nilai rata-rata tetap dan α berperan untuk memberikan bobot terhadap data baru. Model ini dipilih karena cocok untuk *forecasting* jangka pendek dan sering diterapkan pada data yang relatif stabil

untuk menangani fluktuasi data [12]. Rumus single exponential smoothing yaitu :

$$Y_t = \alpha \cdot Y' - 1 + (1 - \alpha) \cdot Y_{t-1} \quad (3)$$

Keterangan :

- Y_t : Peramalan untuk periode t
- α : Parameter Exponential
- $Y' - 1$: Nilai aktual pada waktu ke - t
- Y_{t-1} : Peramalan pada waktu ke - t

F. Perhitungan Akurasi

Langkah berikutnya adalah memvalidasi penelitian tersebut melalui perhitungan akurasi. Tujuan dari perhitungan akurasi ini adalah untuk memastikan bahwa hasil penelitian mencerminkan tingkat keakuratan yang memadai. Oleh karena itu, pengujian akurasi diperlukan sebagai langkah validasi. Dalam penelitian ini, metode perhitungan akurasi forecasting menggunakan *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE) sebagai standar untuk memvalidasi hasil estimasi, sementara perbandingan probabilitas digunakan untuk memvalidasi hasil klasifikasi. Selain itu, untuk validasi hasil klasterisasi, *Silhouette Coefficient* digunakan sebagai ukuran akurasi. *Silhouette Coefficient* mengukur seberapa mirip sebuah objek dengan klasternya sendiri dibandingkan dengan klaster lain, sehingga memberikan indikasi yang jelas tentang validitas struktur klaster yang dihasilkan.

1) Mean Absolute Error

Penelitian yang dilakukan oleh Sarbani, 2022 [13] menjelaskan bahwa Mean Absolute Error (MAE) merupakan metrik utama untuk mengevaluasi kesalahan peramalan secara keseluruhan dari sebuah model. MAE digunakan untuk mengukur seberapa akurat prediksi dengan cara menghitung rata-rata dari nilai absolut dari setiap kesalahan prediksi. Perhitungan MAE dilakukan dengan menjumlahkan nilai absolut dari kesalahan prediksi untuk setiap periode data dan kemudian membaginya dengan jumlah periode data yang dievaluasi. Perhitungan MAE dapat dinyatakan dalam persamaan pada rumus :

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y' - Y_t| \quad (4)$$

Keterangan :

- n : jumlah data
- Y_t : nilai data peramalan
- Y' : nilai data peramalan

2) Mean Absolute Percentage Error

Mean Absolute Percentage Error (MAPE) adalah metode yang mengukur kesalahan absolut pada setiap periode dengan membaginya dengan nilai observasi nyata untuk periode tersebut, kemudian merata-ratakan kesalahan persentase absolut tersebut [14]. Pendekatan ini bermanfaat terutama ketika skala atau besaran variabel peramalan berpengaruh penting dalam mengevaluasi akurasi prediksi. MAPE

menunjukkan seberapa besar kesalahan peramalan dibandingkan dengan nilai sebenarnya. Perhitungan MAPE dapat dinyatakan dalam persamaan pada rumus :

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y' - Y_t|}{Y_t} \times 100\% \quad (5)$$

Keterangan :

- Y' : nilai data aktual
- Y_t : nilai data peramalan
- n : jumlah data

1) Silhouette Coefficient

Silhouette coefficient merupakan metode yang menggabungkan dua pendekatan yakni kohesi dan separasi. Pendekatan kohesi mengukur kedekatan atau hubungan antar objek di

dalam klaster yang sama, sementara pendekatan separasi mengukur seberapa jauh sebuah klaster terpisah dari klaster lainnya [15]. Rumus *Silhouette Coefficient* :

$$a_i = \frac{1}{|A|-1} \sum_{j \in A, j \neq i} d(i, j) \quad (6)$$

Keterangan :

- $a(i)$: perbedaan rata-rata objek (i) ke semua objek lain pada A
- $d(i, j)$: jarak antara i ke j
- A : kluster

G. Presentasi Hasil

Setelah data dianalisis dan kesimpulan ditarik, penting untuk menyajikan temuan secara efektif kepada pemangku kepentingan yang dituju. Presentasi hasil ini melibatkan penyajian data, analisis, dan temuan secara sistematis dan komprehensif. Tujuannya adalah untuk menjelaskan dengan jelas apa yang telah ditemukan selama penelitian, serta implikasi dan kesimpulan yang dapat diambil dari temuan tersebut. Dalam presentasi hasil, informasi yang disajikan berbentuk ringkas namun komprehensif. Ini termasuk grafik, tabel, dan visualisasi lainnya untuk membantu menggambarkan data secara efektif.

III. HASIL DAN PEMBAHASAN

A. Hasil Pengumpulan Data

Pada Tabel 1 merupakan hasil data yang diperoleh dari Rumah Sakit Hidayah Kab. Boyolali, data yang didapatkan merupakan data penggunaan BMHP, berjumlah 104 data dari rentang waktu Januari 2023 – Desember 2023. Variable yang diperoleh diantaranya : nama barang, bulan, jenis BMHP, departemen pengguna, dan pola permintaan. Kategori BMHP yang tercatat dalam data meliputi berbagai jenis kebutuhan medis habis pakai, seperti Jarum Suntik, Antiseptik, Perban dan Plester, Alat Pelindung Diri, Infus dan

Kateter, Farmasi, Alat Bantu Pernapasan, Benang Bedah, Alat Laboratorium & Diagnostik, dan kategori Umum. Kategori ini mencerminkan ragam penggunaan BMHP berdasarkan fungsi dan perannya dalam pelayanan medis di rumah sakit.

TABEL 1
HASIL PENGUMPULAN DATA

| Nama Barang | Jan | ... | Des | Jenis BMHP | Departemen Pengguna | Pola Permintaan |
|------------------|--------|-----|--------|------------|-------------------------|-----------------|
| Sput 1 cc | 147900 | ... | 12000 | Medis | Bedah, IGD, Rawat Jalan | Tidak Terduga |
| Sput 3 cc | 513200 | ... | 503800 | Medis | Bedah, IGD, Rawat Jalan | Stabil |
| Sput 5 cc | 152200 | ... | 113700 | Medis | Bedah, IGD, Rawat Jalan | Stabil |
| Sput 10 cc | 119200 | ... | 112700 | Medis | Bedah, IGD, Rawat Jalan | Stabil |
| Sput 50 cc | 48000 | ... | 61000 | Medis | Bedah, IGD, Rawat Jalan | Tidak Terduga |
| Betadine | 476000 | ... | 358000 | Medis | Bedah, IGD, Rawat Jalan | Stabil |
| Alkohol | 404000 | ... | 347000 | Medis | Bedah, IGD, Rawat Jalan | Stabil |
| | | ... | | | | |
| Glukometer Strip | 43800 | ... | 39000 | Medis | Bedah | Stabil |
| Lampu Operasi | 16900 | ... | 85000 | Medis | Bedah | Stabil |
| Pinset Anatomis | 20500 | ... | 18900 | Medis | Rawat Jalan | Stabil |
| Gunting Bedah | 55000 | ... | 36600 | Medis | ICU | Tidak Terduga |
| Blade Scalpel | 29700 | ... | 39000 | Medis | Bedah | Stabil |
| Kateter IV | 25200 | ... | 24800 | Medis | Poliklinik | Stabil |

B. Hasil Data Preprocessing


Proses transformasi data hal ini bertujuan untuk mengubah data pada variabel jenis BMHP, departemen pengguna, dan pola permintaan dalam yang masih berbentuk kategorikal menjadi numerik, dengan menerapkan proses *one hot encoding* nantinya data akan diubah menjadi bentuk numerik biner, yakni bernilai 0 atau 1.

C. Hasil Implementasi Agglomerative Hierarchical Clustering

Implementasi AHC dalam penelitian ini bertujuan untuk mengelompokkan item BMHP berdasarkan kemiripan jumlah penggunaan dan jenis BMHP sebelum dilakukan proses forecasting hal ini bertujuan untuk mengelompokkan barang bmhp menjadi beberapa cluster. Proses klusterisasi dilakukan tanpa label awal (*unsupervised learning*), dimana setiap item awal dianggap sebagai cluster tunggal. Kemudian secara bertahap, cluster-cluster dengan jarak kemiripan terdekat digabungkan hingga membentuk struktur hierarki.

Visualisasi hasil proses klusterisasi divisualisasikan melalui dendrogram yang menggambarkan proses penggabungan cluster secara hierarkis. Setiap cabang pada

dendrogram merepresentasikan satu atau lebih item bmhp yang digabungkan berdasarkan kemiripan.



Gambar 2. Dendrogram Hasil Clustering

Dendrogram diatas merupakan hasil dari proses *hierarchical cluster* yang dikelompokkan menjadi 3 kluster dengan karakteristik yang berbeda-beda dijelaskan pada Tabel 2. Setiap label di sumbu horizontal mewakili jenis BMHP, sedangkan sumbu vertikal menunjukkan menunjukkan tingkat kemiripan antar item, semakin rendah garis penggabungan maka semakin mirip. Penentuan jumlah kluster sebanyak tiga didasarkan pada kombinasi pendekatan statistik dan pertimbangan praktis. Secara statistik, evaluasi menggunakan Silhouette Score menghasilkan nilai sebesar 0,727. Selain itu, jumlah kluster sebanyak tiga dipilih agar ruang lingkup relevan secara kontekstual karena secara umum penggunaan BMHP di rumah sakit dapat dikategorikan ke dalam tiga kelompok besar.

TABEL 2
KARAKTERISTIK KLASER


| Cluster | Karakteristik Cluster |
|-----------|--|
| Medis | Cluster dengan tingkat penggunaan tinggi yang didominasi oleh jenis BMHP medis digunakan pada departemen IGD dan Rawat Jalan. |
| Umum | Cluster dengan tingkat penggunaan sedang dan bersifat umum, jenis BMHP umum dan tersebar diseluruh departemen rumah sakit. |
| Radiologi | Cluster barang khusus yang digunakan pada laboratorium dengan tingkat penggunaan sedang. Digunakan dalam departemen radiologi. |

D. Hasil Implementasi Single Exponential Smoothing

Setelah data dikelompokkan menggunakan AHC, berikutnya setiap *cluster* dilakukan proses *forecasting* dengan menggunakan nilai alpha sebesar 0.8. Berikut ini merupakan hasil estimasi yang telah dihitung menggunakan python.


Kenaikan pada data aktual cluster medis terjadi pada bulan januari, maret, juni, dan september, kenaikan ini terjadi secara signifikan dari agustus – september (maksimal kenaikan), nilai naik ke 71.982 tetapi setelah itu langsung menurun. Penurunan penggunaan pada data aktual terjadi pada bulan februari, april, juli, oktober, november, dan desember. Penurunan tajam mencapai titik terendah di bulan desember sebesar 53324. Hasil forecast dari cluster medis menunjukkan angka sebesar 59993. Hasil ini menunjukkan terdapat kenaikan dibandingkan data aktual bulan desember 2023, untuk

memanajemen BMHP cluster ini perlu dengan menerapkan safety stock dengan menerapkan jumlah cadangan tambahan berdasarkan penggunaan rata-rata yang disimpan, sertaantisipasi peningkatan ringan sesuai dengan hasil forecast nya.



Gambar 3. Hasil Tren forecasting Cluster 0


Kenaikan pada data aktual cluster umum terjadi pada bulan januari, april, juni, agustus, dan november. Kenaikan maksimum ini terjadi pada bulan juli – agustus (maksimal kenaikan), nilai naik ke 37.804. Kenaikan ini bersifat tajam dan tiba-tiba setelah sebelumnya berada di titik yang cukup rendah. Penurunan penggunaan pada data aktual terjadi pada bulan februari, maret, mei, juli, september, oktober, dan desember. Penurunan secara drastis terjadi pada bulan April – mei sekitar turun sekitar 4000 dan pada bulan agustus – oktober penurunan berturut-turut turun sekitar 6500. Hasil ini membuat cluster umum memiliki fluktuasi yang ekstrem, cluster ini juga mengalami kenaikan yang cukup signifikan yang membuat tren menjadi lebih agresif. Hal ini membuat cluster umum mempunyai sifat tren yang sulit diprediksi. Hasil forecasting dari cluster umum menunjukkan angka sebesar 35293, hasil ini menunjukkan terdapat kenaikan dibandingkan data aktual bulan desember 2023 (sekitar 32.800). Tidak ada peningkatan tajam dalam data forecast. Untuk cluster medis ini sebaiknya digunakan sistem buffer stock secara dinamis karena kebutuhan sering fluktuatif. Implementasinya dilakukan dengan menentukan batas minimum dan maksimum stok yang fleksibel, menggunakan metode forecast yang dilakukan secara berkala (perbulan) agar stok bisa segera disesuaikan apabila mendapati sinyal lonjakan.



Gambar 4. Hasil Tren forecasting Cluster 1

Kenaikan pada data aktual cluster campuran terjadi pada bulan februari, april, mei, juli, oktober, dan november.

Kenaikan maksimum ini terjadi pada bulan mei nilai naik ke 69.500. Sebaliknya, Penurunan penggunaan pada data aktual terjadi pada bulan januari, maret, juni, agustus, september, dan desember. Penurunan secara drastis terjadi pada bulan agustus-september nilai turun ke 19250. Hasil forecasting dari cluster radiologi menunjukkan angka sebesar 30361, hasil ini menunjukkan terdapat kenaikan dibandingkan data aktual bulan desember 2023, kenaikan ini sebesar 2361 atau naik sekitar 8,4 %. Cluster ini memiliki sifat tren yang cukup stabil dan lebih datar menunjukkan bahwasanya cluster radiologi lebih tenang dan tidak menunjukkan pola ekstrem di akhir tahun. Cluster ini hanya perlu penyesuaian ringan terhadap tren stabil, hal ini cukup disikapi dengan pengelolaan standar berbasis tren rata-rata dengan mempertahankan stok pada level moderat karena tren cenderung stabil, artinya pengambilan keputusan pengadaan dapat dilakukan dengan mengacu pada rata-rata penggunaan beberapa bulan terakhir, misalnya 3–6 bulan, untuk memperkirakan kebutuhan ke depan.



Gambar 5. Hasil forecasting Cluster 2


E. Hasil Evaluasi Akurasi

Evaluasi akurasi dari penelitian ini menggunakan 3 pengukuran yakni menggunakan Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), dan Silhouette Coefficient. Sebelum dilakukan proses clustering, hasil evaluasi menunjukkan nilai MAE sebesar 18.769,80 dan MAPE sebesar 61,77%. Nilai MAPE yang tinggi menunjukkan bahwa model memiliki nilai penyimpangan yang cukup besar terhadap data aktual. Hal ini bisa saja disebabkan oleh keragaman pola permintaan antar barang atau fluktuasi yang terlalu tinggi. Setelah dilakukan proses clustering dengan metode AHC sebelum dilakukan proses forecasting menunjukkan peningkatan nilai akurasi yang signifikan, nilai MAE menurun menjadi 3987.45 dan MAPE menurun drastis menjadi 10,06%. Penurunan ini menunjukkan kesalahan prediksi menjadi jauh lebih kecil. Error item per cluster sebagaimana pada tabel berikut:

TABEL 3
ERROR PER-CLUSTER

| Cluster | MAE | MAPE |
|---------|---------|------|
| 0 | 6668.43 | 12% |
| 1 | 2642.66 | 8% |
| 2 | 2651.26 | 9% |

MAE digunakan untuk mengukur rata-rata absolut selisih antara nilai aktual dan nilai prediksi tanpa mempertimbangkan skala relatif terhadap besaran data. MAE cocok digunakan ketika fokusnya adalah seberapa besar deviasi absolut dari prediksi, terutama jika satuan nilai penting. Sementara itu, MAPE mengukur kesalahan dalam bentuk persentase terhadap nilai aktual, sehingga sangat berguna untuk membandingkan akurasi antar produk atau kategori dengan skala yang berbeda. Namun, MAPE bisa menjadi kurang stabil jika nilai aktual sangat kecil. Kombinasi keduanya memberikan gambaran yang lebih lengkap mengenai kinerja model prediksi, baik dari sisi absolut maupun relatif.



Gambar 6. Perbandingan MAE dan MAPE

Proses klusterisasi diukur menggunakan silhouette coefficient dengan hasil sebesar 0,727. Nilai ini menggambarkan kualitas kluster yang baik, dengan pemisahan antar kluster yang jelas dan konsistensi karakteristik di dalam setiap kluster. Secara keseluruhan, hasil dari evaluasi membuktikan bahwa penerapan clustering sebelum forecasting mampu meningkatkan kualitas peramalan secara signifikan.

F. Hasil Rekomendasi penggunaan BMHP

Setelah menerapkan metode AHC dan SES, didapatkan prediksi kebutuhan BMHP yang lebih terarah dan realistis. Rata-rata hasil prediksi penggunaan bulanan per kluster dari model SES kemudian disesuaikan dengan penambahan buffer stock berdasarkan nilai MAPE masing-masing kluster. Metode buffer stock merupakan tambahan persediaan untuk mengantisipasi kemungkinan adanya kekurangan bahan (*stock out*) [16]. Buffer stock juga disiapkan untuk mengantisipasi adanya lonjakan permintaan [17]. Selain itu, penerapan metode ini juga dapat mengantisipasi ketidakpastian pasokan dan permintaan [18]. Semakin tinggi nilai MAPE, semakin besar persentase buffer yang ditambahkan—yakni 10% untuk MAPE < 20%, 20% untuk MAPE antara 20%–50%, dan 30% untuk MAPE ≥ 50%. Strategi ini bertujuan untuk mengantisipasi ketidakpastian permintaan yang tinggi.

Dari hasil yang diperoleh, nilai rekomendasi stok berkisar antara 3.000 hingga lebih dari 150.000 satuan tergantung pada intensitas penggunaan dan tingkat ketidakpastian

permintaannya seperti pada Tabel 3 Sebagai contoh, barang yang tergolong dalam kluster dengan MAPE rendah memiliki prediksi yang lebih akurat sehingga buffer lebih kecil, sedangkan barang-barang dalam kluster dengan pola penggunaan yang fluktuatif memiliki buffer lebih besar untuk menghindari risiko *stockout*. Dengan pendekatan ini, rumah sakit dapat menetapkan jumlah stok yang lebih optimal dan terukur, tidak lagi menyamaratakan kebutuhan seluruh barang. Ini secara langsung mengurangi risiko *overstock* dan *stockout*.

TABEL 4
BFFER STOCK REKOMENDASI

| Nama Barang | Rekomendasi Stock |
|------------------|-------------------|
| Sput 1cc | 42818 |
| Sput 3cc | 514107 |
| Sput 5cc | 42818 |
| Sput 10cc | 42818 |
| Sput 50cc | 246632 |
| | |
| Glukometer Strip | 42818 |
| Pinset Anatomis | 42818 |
| Gunting Bedah | 42818 |
| Blade Scalpel | 42818 |
| Kateter IV | 42818 |

Sebagai bagian dari validasi hasil penelitian, rekomendasi stok yang dihasilkan akan dibandingkan dengan data penggunaan aktual dari rumah sakit dalam periode yang sama. Hasil rekomendasi ini digunakan sebagai bahan evaluasi internal. Artinya, hasil dari model ini mulai dipertimbangkan sebagai acuan pendukung dalam proses pengelolaan stok, meskipun belum menjadi sistem utama.

IV. KESIMPULAN

Penelitian ini menghasilkan rekomendasi pengelolaan Bahan Medis Habis Pakai (BMHP) dengan mengintegrasikan metode Agglomerative Hierarchical Clustering (AHC) dan Single Exponential Smoothing (SES) guna meningkatkan akurasi peramalan dan efisiensi manajemen pengelolaan BMHP. AHC berhasil mengelompokkan BMHP berdasarkan karakteristik penggunaan, dengan nilai Silhouette Coefficient sebesar 0,727, menandakan kualitas klusterisasi yang baik dan representatif. Setelah dilakukan klusterisasi, performa model SES meningkat secara signifikan, ditunjukkan oleh penurunan nilai MAE dari 18.769,80 menjadi 3.987,45 dan MAPE dari 61,77% menjadi 10,06%, yang menandakan bahwa prediksi menjadi jauh lebih akurat dan relevan. Rekomendasi stok disesuaikan dengan karakteristik masing-masing kluster: Cluster Medis yang memiliki pola fluktuatif tinggi disarankan menggunakan safety stock untuk mengantisipasi lonjakan musiman; Cluster Umum yang menunjukkan ketidakpastian tinggi memerlukan buffer stock dinamis dengan batas minimum dan maksimum berdasarkan tren historis; dan Cluster Campuran yang relatif stabil dapat dikelola dengan pendekatan standar berbasis rata-rata tren 3–

6 bulan terakhir. Klasterisasi ini memberikan dasar yang kuat bagi penerapan kebijakan manajemen stok yang berbeda untuk setiap kelompok barang, sehingga mampu menjawab permasalahan overstock dan stockout. Hubungan antara hasil peramalan dan klasterisasi menciptakan rekomendasi yang tidak hanya bersifat kuantitatif, tetapi juga kontekstual terhadap kondisi nyata di rumah sakit. Namun, penelitian ini memiliki keterbatasan karena belum mempertimbangkan variabel eksternal seperti tindakan medis atau epidemi, dan hanya menggunakan data dari satu institusi dalam periode tertentu, yang membatasi generalisasi hasil penelitian.

DAFTAR PUSTAKA

- [1] T. I. Pratiwi, B. C. Octariadi, S.Kom.,M.Cs, and Y. Brianorman,S.Si.,M.T, "Sistem Informasi Peramalan Persediaan Roti Menggunakan Metode Single Exponential Smoothing Pada Pabrik Teguh Karya Bakery," *Digital Intelligence*, vol. 2, no. 2, p. 72, Apr. 2022, doi: 10.29406/diligent.v2i2.3286.
- [2] K. Atma Wijaya and D. Swanjaya, "Integrasi Metode Agglomerative Hierarchical Clustering dan Backpropagation Pada Model Peramalan Penjualan," 2021.
- [3] A. Ikbal, A. I. Purnamasari, and I. Ali, "Analisis Klasterisasi Untuk Prediksi Jumlah Kasus Dbd Berdasarkan Jenis Kelamin Dan Kabupaten/Kota Di Jawa Barat," 2023.
- [4] D. Astuti, D. Y. Hartanti, S. T. Nurhayanti, and H. Fransiska, "Clustering and Forecasting of Covid-19 Data in Indonesia," *Jurnal Matematika, Statistika dan Komputasi*, vol. 18, no. 3, pp. 324–335, May 2022, doi: 10.20956/j.v18i3.18882.
- [5] M. A. Sundari, R. Pane, and R. Rohani, "Data Mining Clustering Korban Kejahatan Pelecehan Seksual dengan Kekerasan Berdasarkan Provinsi Menggunakan Metode AHC," *Building of Informatics, Technology and Science (BITS)*, vol. 5, no. 1, Jun. 2023, doi: 10.47065/bits.v5i1.3499.
- [6] S. N. Budiman, A. History, and N. Budiman, "Jurnal Teknologi dan Manajemen Informatika Peramalan Stock Barang Dagangan Menggunakan Metode Single Exponential Smoothing Article Info ABSTRACT," *Jurnal Teknologi dan Manajemen Informatika*, vol. 7, no. 2, pp. 113–121, 2021, [Online]. Available: <http://http://jurnal.unmer.ac.id/index.php/jtmi>
- [7] S. Mulyani, D. Hayati, A. N. Sari, and S. Nasional Banjarmasin, "Analisis Metode Peramalan (Forecasting) Penjualan Sepeda Motor Honda Dalam Menyusun Anggaran Penjualan Pada Pt Trio Motor Martadinata Banjarmasin," 2021.
- [8] A. Nurlifa and S. Kusumadewi, "Sistem Peramalan Jumlah Penjualan Menggunakan Metode Moving Average Pada Rumah Jilbab Zaky," vol. 2, no. 1, p. 2017.
- [9] H. Yulius and I. Yetti, "Jurnal Edik Informatika Penelitian Bidang Komputer Sains dan Pendidikan Informatika V1.i1(5-14) 5 Diterbitkan Oleh Program Studi Pendidikan Informatika STKIP PGRI Sumbar Peramalan Kebutuhan Manajemen Logistik Pada Usaha Depot Air Minum Isi Ulang Al-Fitrah", doi: 10.22202/jei.2014.v1i1.1430.
- [10] D. A. Sri Nawangwulan, "Analisis Time Series Metode Winter Jumlah Penderita Gastroenteritis Rawat Inap Berdasarkan Data Rekam Medis Di Rsud Dr. Soetomo Surabaya," *Jurnal Manajemen Kesehatan STIKES Yayasan RS. Dr. Soetomo*, vol. 2, no. 1, pp. 17–32, 2019.
- [11] M. Rizal Kurniawan, J. Dedy Irawan, and F. Santi Wahyuni, "Forecasting Penjualan Kopi Dengan Metode Exponential Smoothing Berbasis Web (Studi Kasus Kedai Psycoffee)," 2021.
- [12] I. Larasati *et al.*, "Forecasting Produksi Perikanan Laut Yang Dijual Di Tpi (Ton) Dengan Metode Single Exponential Smoothing," 2020.
- [13] S. Sarbaini and E. Safitri, "Penerapan Metode Single Exponential Smoothing dalam Memprediksi Jumlah Peserta Pelatihan Masyarakat," *Lattice Journal : Journal of Mathematics Education and Applied*, vol. 2, no. 2, p. 103, Dec. 2022, doi: 10.30983/lattice.v2i2.5937.
- [14] H. Dimas Prasetya, M. A. Ineke Pakereng, and K. Satya Wacana, "Prediksi Jumlah Produksi Terhadap Kebutuhan Pasar di PT. Morich Indo Fashion Menggunakan Metode Single Exponential Smoothing," *Jurnal Teknologi Informasi dan Komunikasi*, vol. 7, no. 1, p. 2023, 2023, doi: 10.35870/jti.
- [15] H. Prayoga *et al.*, "Penerapan Metode AHC Ward dalam Mengelompokkan Data UKM di Kecamatan Umbulharjo," vol. 10, no. 1, pp. 1–8, 2022, doi: 10.12928/jstie.v8i3.xxx.
- [16] S. Setiyawati, N. Umilia Purwanti, and J. Hadari Nawawi, "Analysis Of Psychotropic Inventory Control Using Abc, Eoq, And Buffer Stock Methods In Mental Hospital Sungai Bangkok Pontianak," 2022.
- [17] W. W. Rohimah and Y. Siyamto, "Optimalisasi Pengelolaan Perbekalan Farmasi dalam Menunjang Ketersediaan Obat di Rumah Sakit," *Jurnal Ilmiah Keuangan Akuntansi Bisnis*, vol. 3, no. 3, pp. 590–596, Oct. 2024, doi: 10.53088/jikab.v3i3.167.
- [18] A. Ferry Qadafi and A. D. Wahyudi, "Sistem Informasi Inventory Gudang Dalam Ketersediaan Stok Barang Menggunakan Metode Buffer Stok," *Jurnal Informatika dan Rekayasa Perangkat Lunak (JATIKA)*, vol. 1, no. 2, pp. 174–182, 2020, [Online]. Available: <http://jim.teknokrat.ac.id/index.php/informatika>