

**IMPLEMENTASI *MACHINE LEARNING* DALAM MEMPREDIKSI
JUMLAH PENDONOR DARAH DENGAN MENGGUNAKAN
MODEL *AUTOREGRESSIVE INTEGRATED MOVING AVERAGE*
(ARIMA) DAN *EXPONENTIAL MOVING AVERAGE* (EMA)
(STUDI KASUS : PMI KABUPATEN SLEMAN)**

TUGAS AKHIR

**Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Strata-1
Program Studi Teknik Industri - Fakultas Teknologi Industri
Universitas Islam Indonesia**



Nama : Muhammad Tri Rahffi

No. Mahasiswa : 19522350

**PROGRAM STUDI TEKNIK INDUSTRI PROGRAM SARJANA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA
2024**

PERNYATAAN KEASLIAN

Saya mengakui bahwa tugas akhir ini adalah hasil karya saya sendiri kecuali kutipan dan ringkasan yang seluruhnya sudah saya jelaskan sumbernya. Jika dikemudian hari ternyata terbukti pengakuan saya ini tidak benar dan melanggar peraturan yang sah maka saya bersedia ijazah yang telah saya terima ditarik kembali oleh Universitas Islam Indonesia.

Yogyakarta, 9 April 2024



Muhammad Tri Rahffi
19522350

SURAT BUKTI PENELITIAN



SURAT KETERANGAN
No: 116/020503/UDD/III/2024

Yang bertanda tangan di bawah ini :

Nama : dr. Dona Yuan Giovina
Jabatan : Kepala UDD PMI Kabupaten Sleman


Menerangkan bahwa yang tersebut di bawah ini :

Nama : Muhammad Tri Rahffi
NIM : 19522350
Perguruan Tinggi : Universitas Islam Indonesia
Program Studi : Teknik Industri
Judul Penelitian : Implementasi Machine Learning Dalam Memprediksi Jumlah
Kebutuhan Tenaga Medis Dengan Menggunakan Model ARIMA
(Studi Kasus: PMI Sleman)

Adalah benar telah melaksanakan kegiatan Penelitian dan melakukan pengambilan data di Unit Donor Darah (UDD) PMI Kabupaten Sleman selama periode 10 Januari 2024 sampai dengan 15 Februari 2024. Selama melaksanakan kegiatan Penelitian tersebut yang bersangkutan melaksanakan tugas dan tanggung jawabnya dengan baik.

Demikian surat keterangan ini dibuat untuk digunakan sebagaimana mestinya.

Sleman, 06 Maret 2024
Unit Donor Darah
PALANG MERAH INDONESIA
Kabupaten Sleman

Kepala



dr. Dona Yuan Giovina

Markas PMI Kabupaten Sleman : Jl. Radjimin, Sucen, Triharjo, Sleman 55514

Telp./Fax : Sekretariat : (0274) 868900; Emergency Call : (0274) 868900; UDD : (0274) 868909; Klinik Pratama : (0274) 868900

LEMBAR PENGESAHAN PEMBIMBING

**IMPLEMENTASI *MACHINE LEARNING* DALAM MEMPREDIKSI
JUMLAH PENDONOR DARAH DENGAN MENGGUNAKAN
MODEL *AUTOREGRESSIVE INTEGRATED MOVING AVERAGE*
(ARIMA) DAN *EXPONENTIAL MOVING AVERAGE* (EMA)
(STUDI KASUS : PMI KABUPATEN SLEMAN)**



TUGAS AKHIR

Disusun Oleh:

Nama : Muhammad Tri Rahffi

No. Mahasiswa : 19522350

Yogyakarta, 9 April 2024

Dosen Pembimbing



(Dr. Ir. Agus Mansur, S.T., M.Eng.Sc., IPU.)

LEMBAR PENGESAHAN DOSEN PENGUJI

**IMPLEMENTASI *MACHINE LEARNING* DALAM MEMPREDIKSI JUMLAH
KEBUTUHAN PENDONOR DARAH DENGAN MENGGUNAKAN MODEL
AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) DAN
EXPONENTIAL MOVING AVERAGE (EMA)
(STUDI KASUS : PMI KABUPATEN SLEMAN)**

TUGAS AKHIR

Disusun Oleh :

Nama : Muhammad Tri Rahffi
No. Mahasiswa : 19522350

Telah dipertahankan di depan sidang pengujian sebagai salah satu syarat untuk memperoleh gelar Sarjana Strata-1 Teknik Industri Fakultas Teknologi Industri Universitas Islam Indonesia

Yogyakarta, 30 - April – 2024

Tim Penguji

Dr. Ir. Agus Mansur, S. T., M. Eng. Sc., IPU
Ketua

Annisa Uswatun Khasanah, S.T., M.Sc.
Anggota I


Wahyudhi Sutrisno, S.T., M.M., M.T
Anggota II





Mengetahui,

Ketua Program Studi Teknik Industri Program Sarjana
Fakultas Teknologi Industri
Universitas Islam Indonesia



Ir. Muhammad Ridwan Nurdi Pulnento, S. T., M. Sc., Ph. D., IPM

NIK. 015220101

HALAMAN PERSEMBAHAN

Alhamdulillahirabbil'alamin

Laporan tugas akhir ini penulis dedikasikan kepada kedua orang tua tercinta Ibu saya Rina Rosama dan bapak Jumli, abang, dan kakak, serta sahabat yang selalu memberi dukungan penuh, serta memotivasi semangat tak ternilai, dan doa yang tulus dari hati. Serta kepada Bapak Agus Mansur selaku dosen pembimbing yang terus membimbing penulis serta memberi arahan dalam pengerjaan tugas akhir, dan untuk program studi penulis Teknik Industri.

Tak lupa, laporan tugas akhir ini saya persembahkan untuk diri saya sendiri sebagai bentuk apresiasi, karena sudah sapat bertahan sejauh ini. Semoga dengan selesainya skripsi dapat membuat saya terus semangat dan bersyukur kepada Allah SWT. karena telah dilancarkan dan nikmat ilmu yang berlimpah.

MOTTO

“Allah tidak mengatakan hidup ini mudah. Tetapi Allah berjanji, bahwa sesungguhnya
Bersama kesulitan ada kemudahan.”

Q. S Al-Insyirah(5-6)

Dan satu lagi, “Allah tidak membebani seseorang melainkan sesuai dengan
kemampuannya.”

Q. S. al-Baqarah ayat 286

“Perjalanan ku memang pelan tapi langkah kakiku takkan pernah melangkah mundur.”

Jack Ma

KATA PENGANTAR

Bismillahirrahmanirrahim

Assalamu 'alaikum Warahmatullahi Wabarakatuh

Alhamdulillah, segala puji syukur atas kehadiran Allah SWT yang telah melimpahkan rahmat dan hidayah-Nya, sehingga penulis dapat melaksanakan dan menyelesaikan penulisan laporan Tugas Akhir dalam keadaan sehat sentosa. Sholawat serta salam tak lupa dipanjatkan kepada junjungan kita Nabi Agung Muhammad *Shalallahu 'Alaihi Wasallam*, semoga syafaatnya selalu didapatkan sampai akhir zaman nanti.

. Karya tulis ini dibuat sebagai satu syarat kelulusan untuk menyelesaikan Program Studi Teknik Industri Program Sarjana, Fakultas Teknologi Industri, Universitas Islam Indonesia. Penulisan serta penyusunan Tugas Akhir ini tentunya terdapat kesulitan, masalah, dan kendala yang dialami penulis selama menyusun laporan Tugas Akhir ini. Namun, semua hal tersebut akhirnya mampu dilewati oleh penulis. Keberhasilan penyusunan Tugas Akhir ini tentu tidak terlepas dari kerja sama, motivasi, dan keterlibatan berbagai pihak yang turut membantu dan membimbing hingga selesai. Oleh karenanya, penulis ingin mengucapkan terima kasih kepada:

1. Bapak Prof., Dr., Ir., Hari Purnomo, M.T., IPU, ASEAN., selaku Dekan Fakultas Teknologi Industri Universitas Islam Indonesia.
2. Bapak Ir. Muhammad Ridwan Andi Purnomo, S.T., M.Sc., Ph.D., IPM, selaku Ketua Program Studi Teknik Industri, Fakultas Teknologi Industri, Universitas Islam Indonesia.
3. Bapak Dr. Ir. Agus Mansur, S.T., M.Eng.Sc., IPU selaku dosen pembimbing tugas akhir yang telah memberikan bimbingan, ilmu, arahan, dan meluangkan waktunya di sela-sela kesibukan dari awal penulisan laporan tugas akhir hingga selesai.
4. Bapak Soeradji selaku ketua di PMI Kabupaten Sleman dan Mas Adrian sebagai sekertarisnya yang telah mengizinkan dan membantu penulis untuk melakukan penelitian hingga selesai di PMI Kabupaten Sleman

5. Kedua orang tua saya Ibu Rina Rosma dan Bapak Jumli serta abang dan kakak yang tak hentinya selalu memberikan doa, motivasi, semangat, kasih sayang dan dukungan baik moral maupun material.
6. Seluruh teman kelas F Teknik Industri Angkatan 2019, yang menjadi teman baik dan saling mendukung dari semester satu sampai sekarang.
7. Fahreza Adrian Khasa dan Arif Trio Anggara selaku sahabat penulis dari awal mendaftar kuliah yang selalu memberi dukungan dan motivasi selama penyusunan tugas akhir ini.
8. Siti Nur Fajriah, Ade Tama, Ade Satria, Crecenda Della, Woro Nabila, dan Ajeng selaku sahabat saya dari perantauan yang telah menemani penulis dalam berprogres.
9. Seluruh kerabat, teman dan pihak yang telah berbaik hati membantu penulis memberikan segala kontribusinya sehingga laporan tugas akhir ini terselesaikan.

Semoga segala bantuan, dukungan, dan bimbingan yang telah diberikan menjadi amal baik bagi semua pihak yang telah berperan. Penulis menyadari bahwa laporan ini masih jauh dari sempurna. Oleh karena itu, penulis menerima segala kritik dan saran yang membangun guna perbaikan ke depannya. Penulis berharap laporan ini dapat bermanfaat bagi pembaca.

Wassalamu'alaikum Warahmatullahi Wabarakatuh.

Yogyakarta, 9 April 2024

Muhammad Tri Rahffi

NIM 19522350

ABSTRAK

Darah merupakan komponen penting di dalam tubuh manusia yang berperan dalam memberikan supply oksigen, makanan, dan zat lain yang dibutuhkan oleh tubuh. Palang Merah Indonesia (PMI) adalah sebuah organisasi perhimpunan nasional di Indonesia yang bergerak dalam bidang sosial kemanusiaan. Unit Donor Darah (UDD) merupakan fasilitas pelayanan kesehatan yang menyelenggarakan upaya -upaya kesehatan seperti donor darah, penyediaan darah, dan distribusi darah. Permasalahan yang dihadapi PMI Kabupaten Sleman belum dapat memprediksi SDM pendonor darah setiap kegiatan donor darah yang diselenggarakan sehingga dapat menyebabkan kurangnya efektifitas dan efisien kinerja dari karyawan PMI Sleman, maka dari itu PMI Kabputen Sleman harus meramalkan jumlah pendonor untuk kedepannya. Oleh karena itu, dilakukan penelitian dengan tujuan untuk memprediksi dari sektor SDM pendonor darah dengan menggunakan ARIMA dan EMA yang diproses dengan menggunakan Bahasa pemograman Rstudio. Untuk pengujian tingkat error dilakukan dengan menggunakan *Mean Absolute Percentage Error* (MAPE). Hasil pemodelan menunjukkan bahwa performa metode EMA memiliki tingkat error yang lebih rendah dari pada ARIMA, yang Dimana hasil testing dan trainingnya memiliki nilai rata-rata MAPE 13% dan 15% yang dinilai memiliki akurasi yang lebih baik. Sehingga dapat EMA diketahui metode yang lebih baik digunakan untuk peramalan jumlah pendonor darah, mengoptimalkan jadwal pertemuan donor darah, mengurangi risiko kekurangan atau kelebihan stok darah, dan meningkatkan efisiensi dalam pelayanan transfusi darah kepada pasien. Selain itu, prediksi jumlah pendonor darah juga dapat menjadi dasar untuk mengembangkan strategi promosi dan kampanye donor darah yang lebih efektif untuk meningkatkan partisipasi masyarakat dalam kegiatan donor darah.

Kata Kunci: SDM Pendonor Darah, ARIMA, EMA, MAPE.

DAFTAR ISI

HALAMAN JUDUL	i
PERNYATAAN KEASLIAN	ii
SURAT BUKTI PENELITIAN	iii
LEMBAR PENGESAHAN PEMBIMBING	iv
LEMBAR PENGESAHAN DOSEN PENGUJI	v
HALAMAN PERSEMBAHAN	vi
MOTTO	vii
KATA PENGANTAR.....	viii
ABSTRAK	x
DAFTAR ISI	xi
DAFTAR TABEL	xiii
DAFTAR GAMBAR.....	xiv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian.....	3
1.4 Manfaat Penelitian.....	4
1.5 Batasan Penelitian	4
BAB II TINJAUAN PUSTAKA	5
2.1 Kajian Literatur	5
2.2 Landasan Teori.....	15
2.2.1 Machine Learning	15
2.2.2 Data.....	15
2.2.2.1 Klasifikasi Berdasarkan Sifat Data	16
2.2.2.2 Klasifikasi Berdasarkan Waktu Pengumpulanya.....	16
2.2.3 <i>Time Series</i>	16
2.2.4 Stasioneritas	17
2.2.5 <i>Autoregressive Integrated Moving Average (ARIMA)</i>	17
2.2.6 <i>Exponential Moving Average (EMA)</i>	18
2.2.7 Pengujian Tingkat Eror	19
2.2.7.1 <i>Scale Dependent Measure</i>	19
2.2.7.2 <i>Precentage Measure</i>	19
BAB III METODE PENELITIAN	21
3.1 Objek Penelitian	21
3.2 Pengumpulan Data	21
3.3 Alur Penelitian.....	22

BAB IV PENGUMPULAN DAN PENGOLAHAN DATA	26
4.1 Pengumpulan Data	26
4.2 <i>Pre-Processing</i> Data.....	27
4.2.1 Persiapan Data	27
4.3 Pemodelan ARIMA	28
4.3.1 Identifikasi Model.....	28
4.3.2 <i>Differencing</i>	29
4.3.3 Estimasi Parameter Model	29
4.3.4 Evaluasi Model ARIMA	32
4.4 <i>Exponential Moving Average (EMA)</i>	32
4.4.1 Evaluasi Hasil Peramalan <i>Exponential Moving Average</i>	33
4.4.2 Melakukan Peramalan Periode Kedepan	33
BAB V HASIL DAN PEMBAHASAN	34
5.1 Analisis Deskriptif.....	34
5.2 Stasioneritas.....	35
5.3 Analisis Pemodelan ARIMA.....	36
5.4 <i>Exponential Moving Average (EMA)</i>	39
5.5 Evaluasi Model.....	41
5.6 Hasil Peramalan Periode Kedepan	41
5.7 Implikasi Manajerial.....	43
BAB VI PENUTUP.....	45
6.1 Kesimpulan.....	45
6.2 Saran.....	45
DAFTAR PUSTAKA.....	46
LAMPIRAN	A-1

DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu.....	13
Tabel 4. 1 Entitas Data.....	26
Tabel 5. 1 Analisis Deskriptif.....	34
Tabel 5.2 Hasil Uji Stasioneritas	36
Tabel 5. 3 Perbandingan Hasil Peramalan vs Data <i>Testing</i>	40
Tabel 5. 4 Perbandingan Metode Peramalan	41
Tabel 5. 5 Hasil Peramalan Lima Periode Kedepan	42

DAFTAR GAMBAR

Gambar 1. 1 Data Karyawan PMI Sleman	2
Gambar 3. 1 <i>Flowchart</i> Alur Penelitian.....	22
Gambar 4.1 Data Historis Jumlah Pendonor.....	26
Gambar 4.2 <i>Syntax</i> Memanggil Data.....	28
Gambar 4.3 Eksplorasi Data <i>Time Series</i>	29
Gambar 4.4 Melakukan Identifikasi Model.....	29
Gambar 4.5 Membuat Model ARIMA Jumlah Pendonor	30
Gambar 4. 6 <i>Function</i> Untuk Uji Signifikansi Parameter Model ARIMA	31
Gambar 4. 7 Prediksi Data <i>Testing</i> Jumlah Pendonor	31
Gambar 4. 8 Evaluasi Hasil Peramalan dengan MAPE.....	32
Gambar 4. 9 <i>Syntax</i> Metode EMA 2 Periode Jumlah Pendonor	32
Gambar 4. 10 <i>Syntax</i> Menggambar Plot EMA Jumlah Pendonor	32
Gambar 4. 11 Evaluasi Hasil Peramalan dengan MAPE Jumlah Pendonor Data <i>Training</i> dan Data <i>Testing</i>	33
Gambar 4. 12 <i>Syntax</i> Peramalan Lima Periode Kedepan.....	33
Gambar 5.1 <i>Plot</i> Data Aktual.....	35
Gambar 5.2 Hasil Uji Stasioneritas	35
Gambar 5.3 <i>Plot</i> ACF dan PACF	36
Gambar 5. 4 <i>Summary</i> Model 1 ARIMA	37
Gambar 5.5 Melihat Signifikansi dari Koefisien Model 1	37
Gambar 5. 6 <i>Plot</i> Uji <i>Diagnostic</i>	38
Gambar 5. 7 Prediksi Data <i>Testing</i> Data Jumlah Pendonor Darah.....	39
Gambar 5. 8 <i>Plot</i> EMA(2) Jumlah Pendonor Darah.....	39
Gambar 5. 9 Data teratas Hasil Peramalan EMA Jumlah Pendonor Darah <i>Training</i>	40
Gambar 5. 10 Data Hasil Peramalan EMA Jumlah Pendonor Darah Data <i>Testing</i>	40
Gambar 5. 11 Hasil Peramalan Lima Periode Kedepan	42
Gambar 5. 12 Grafik Data Aktual dan Peramalan Lima Periode Kedepan Jumlah Pendonor Darah	42

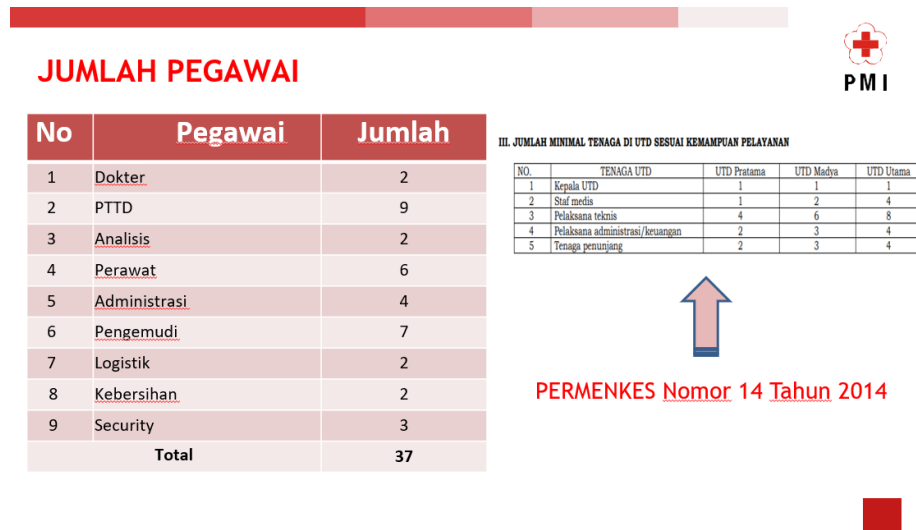
BAB I

PENDAHULUAN

1.1 Latar Belakang

Darah merupakan komponen penting di dalam tubuh manusia yang berperan dalam memberikan supply oksigen, makanan, dan zat lain yang dibutuhkan oleh tubuh. Pada beberapa situasi, untuk memenuhi kebutuhan darah, seseorang memerlukan pasokan darah dari luar melalui proses transfusi. Banyak sekali penyakit yang membuat seseorang mengalami kekurangan darah, sehingga perlu melakukan transfusi darah dari orang lain (Andyani & Juniarta, 2020). Oleh karena itu setiap rumah sakit idealnya harus mempunyai dan memastikan stok darah yang mencukupi untuk berjaga-jaga ketika ada pasien yang membutuhkan dalam keadaan darurat seperti pasien-pasien di UGD, ibu yang mengalami pendarahan setelah melahirkan, korban kecelakaan, dan kondisi genting lainnya. Resiko yang dapat ditimbulkan jika terjadi keterlambatan transfusi akibat terjadinya kekosongan stok darah akan memberikan resiko yang fatal bagi pasien hingga dapat berujung terjadinya kematian.

Palang Merah Indonesia (PMI) adalah sebuah organisasi perhimpunan nasional di Indonesia yang bergerak dalam bidang sosial kemanusiaan. PMI selalu berpegang teguh pada tujuh prinsip dasar gerakan Internasional Palang Merah dan Bulan sabit merah yaitu kemanusiaan, kesamaan, kesukarelaan, kemandirian, kesatuan, kenetralan dan kesemestaan. Palang Merah Indonesia dalam pelaksanaannya tidak melakukan pembedaan tetapi mengutamakan korban yang paling membutuhkan pertolongan segera keselamatan jiwanya. Unit transfusi darah PMI yang selanjutnya disebut UTD PMI adalah unit penyelenggara pengolahan transfusi darah pada PMI. Unit Donor Darah (UDD) merupakan fasilitas pelayanan kesehatan yang menyelenggarakan upaya -upaya kesehatan seperti donor darah, penyediaan darah, dan distribusi darah (Kementrian Kesehatan RI, 2014). Komponen darah yang sudah diolah kemudian didistribusikan dari UDD ke Bank Darah Rumah Sakit (BDRS) yang meminta untuk diberikan ke pasien yang membutuhkan transfusi.



Gambar 1. 1 Data Karyawan PMI Sleman

Sumber: Data PMI Sleman

Fasilitas pelayanan kesehatan yang menyelenggarakan upaya-upaya kesehatan seperti donor darah, penyediaan darah, dan distribusi darah dibutuhkan sumber daya manusia yang memumpunin untuk memenuhi jumlah setiap donor darah baik dari segi pendonor darah maupun tenaga ahli medis. Permasalahan PMI Kabupaten Sleman belum dapat memprediksi SDM pendonor darah setiap kegiatan donor darah yang diselenggarakan sehingga dapat menyebabkan kurangnya efektifitas dan efisien kinerja dari karyawan PMI Sleman, maka dari itu PMI Kabupaten Sleman harus meramalkan jumlah pendonor untuk kedepannya. Dengan menggunakan pendekatan kuantitatif, peramalan seri waktu adalah peramalan untuk masa depan berdasarkan data masa lalu. *Machine learning* adalah salah satu metode peramalan seri waktu yang dapat digunakan dan sangat akurat. Menurut (Fathurohman, 2021). Algoritma yang berbasis pembelajaran mesin adalah salah satu algoritma yang sangat baik yang telah dipelajari secara menyeluruh dan memiliki kemampuan untuk melakukan peramalan yang akurat (Fahmi et al., 2015). Metode *machine learning* yang dapat diaplikasikan dalam peramalan ini adalah metode *Autoregressive Integrated Moving Average* (ARIMA) dan *Exponential Moving Average* (EMA).

Metode ARIMA ialah metode dengan membuat model peramalan jangka pendek yang akurat yang sepenuhnya mengabaikan independen variabel dengan menggunakan

data time series. Metode ini banyak digunakan dalam melakukan peramalan jangka pendek (Fauzani & Rahmi, 2023). ARIMA mengkombinasikan model *autoregressive* dan *moving average*. Kelebihan dari ARIMA adalah memiliki sifat yang fleksibel (mengikuti pola data), memiliki tingkat akurasi peramalan yang cukup tinggi dan cocok digunakan untuk meramal sejumlah variabel yang cepat, sederhana, akurat, dan murah (Kolker, 2011). Sedangkan metode EMA Menurut (Mahadewa et al., 2018), EMA atau yang dikenal Exponential Moving Average merupakan penyempurnaan dari metode Single Moving Average (SMA). Pemberian bobot pada EMA melibatkan periode, jadi semakin panjang periode yang kita gunakan maka semakin kecil pembobotan nilai terakhir yang kita gunakan. Dalam penelitian ini akan dibandingkan antara peramalan ARIMA dan EMA. Perbandingan dilakukan dengan melihat nilai MAPE (Mean Absolute Percentage Error) yang didapatkan dari masing-masing metode, sehingga dapat diketahui metode yang lebih baik digunakan untuk peramalan jumlah pendonor darah, mengoptimalkan jadwal pertemuan donor darah, mengurangi risiko kekurangan atau kelebihan stok darah, dan meningkatkan efisiensi dalam pelayanan transfusi darah kepada pasien. Selain itu, prediksi jumlah pendonor darah juga dapat menjadi dasar untuk mengembangkan strategi promosi dan kampanye donor darah yang lebih efektif untuk meningkatkan partisipasi masyarakat dalam kegiatan donor darah.

1.2 Rumusan Masalah

Rumusan masalah pada penelitian berikut ini:

1. Metode apakah yang memiliki tingkat error yang rendah sehingga dapat dijadikan sebagai rekomendasi metode untuk menentukan jumlah pendonor darah?
2. Bagaimana menentukan prediksi jumlah pendonor darah dengan memanfaatkan *machine learning* dengan menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) dan *Exponential Moving Average* (EMA) di PMI Kabupaten Sleman?

1.3 Tujuan Penelitian

Adapun tujuan pada penelitian yang dilakukan di PMI Sleman adalah sebagai berikut:

1. Mengetahui metode yang memiliki tingkat error yang rendah sehingga dapat dijadikan sebagai rekomendasi metode untuk menentukan jumlah pendonor darah.
2. Mendapatkan model prediksi jumlah pendonor darah yang berbasis *machine learning* dengan menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) dan *Exponential Moving Average* (EMA) untuk jumlah pendonor darah di PMI Kabupaten Sleman.

1.4 Manfaat Penelitian

Adapun manfaat dari penelitian diantaranya:

1. Bagi keilmuan
Membantu pengembangan ilmu pengetahuan dalam kajian keilmuan dan perkembangan teknologi, serta hasil penelitian ini diharapkan dapat dijadikan pembelajaran yang berguna bagi penelitian lainnya.
2. Bagi Perusahaan
Membantu Perusahaan dalam menyelesaikan permasalahan yang ada yaitu dalam melakukan peramalan, permintaan, dan menjadi faktor pertimbangan dalam pengambilan Keputusan.

1.5 Batasan Penelitian

Ada Batasan pada permasalahan dalam penelitian ini untuk berkonsentrasi pada masalah-masalah yang telah ditetapkan sebelumnya:

1. Penelitian dilakukan di PMI Sleman.
2. Penelitian difokuskan pada prediksi jumlah pendonor darah dan analisis terhadap jumlah pendonor seriap kegiatan donor darah di PMI Sleman.
3. Pengambilan data historis jumlah jumlah pendonor darah dari setiap kegiatan dalam jangka waktu Oktober, November, dan Desember 2023.

BAB II TINJAUAN PUSTAKA

2.1 Kajian Literatur

Tinjauan Pustaka diawali dengan melakukan kajian literatur yang berisi tentang penelitian-penelitian terdahulu yang telah dilakukan sebagai referensi bagi peneliti dengan topik penelitian yang berkaitan:

Penelitian yang dilakukan oleh ArunKumar et al. (2022) dengan judul “*Comparative analysis of Gated Recurrent Units (GRU), long Short-Term memory (LSTM) cells, autoregressive Integrated moving average (ARIMA), seasonal autoregressive Integrated moving average (SARIMA) for forecasting COVID-19 trends*”. Penelitian ini bertujuan untuk menganalisis rangkaian waktu komparatif dari teknik pembelajaran mendalam (jaringan neural berulang dengan sel GRU dan LSTM) dan teknik statistik (ARIMA dan SARIMA) untuk memperkirakan kumulatif konfirmasi, pemulihan, dan kematian berdasarkan negara. Sel *Gated Recurrent Units (GRU)*, *Long Short-Term Memory (LSTM)* berdasarkan model *Recurrent Neural Networks (RNN)*, ARIMA, dan SARIMA dilatih, diuji, dan dioptimalkan untuk memperkirakan tren COVID-19. Dengan menerapkan *python* untuk mengoptimalkan parameter ARIMA yang mencakup (p, d, q) yang mewakili suku autoregresif dan rata-rata bergerak, dan parameter model SARIMA menyertakan suku musiman tambahan yang dilambangkan dengan (P, D, Q). Demikian pula, untuk parameter model RNN berbasis LSTM dan GRU (jumlah lapisan, ukuran tersembunyi, kecepatan pembelajaran, dan jumlah zaman) dioptimalkan dengan menerapkan kerangka pembelajaran mesin PyTorch. Model terbaik dipilih berdasarkan nilai *Mean Square Error (MSE)* dan *Root Mean Squared Error (RMSE)* terendah. Pada sebagian besar data deret waktu di negara-negara tersebut, model berbasis pembelajaran mendalam LSTM dan GRU mengungguli model statistik ARIMA dan SARIMA, dengan nilai RMSE 40 kali lipat lebih rendah dibandingkan model ARIMA.

Penelitian yang dilakukan oleh Chyon et al. (2022) dengan judul “*Time series analysis and predicting COVID-19 affected patients by ARIMA model using machine learning*”. Penyebaran sindrom pernafasan yang dikenal sebagai Penyakit Virus Corona

2019 (COVID-19) dengan cepat menjadi pandemi dan mempengaruhi lebih dari 192 negara. Keadaan darurat sistem kesehatan diwajibkan untuk menanggapi epidemi ini. Meskipun tindakan pembendungan penyakit di Tiongkok berhasil mengurangi kasus baru sebanyak lebih dari 90%, tingkat penurunannya tidak sama dengan yang terjadi di negara-negara lain. Jadi, pertanyaan yang muncul adalah: bagaimana dunia akan melihat pandemi ini, dan berapa banyak pasien yang bisa terkena dampaknya? Respons yang diberikan akan sangat membantu dan mendukung pihak berwenang dan masyarakat dalam mempersiapkan diri menghadapi hari-hari mendatang. Dalam studi ini, model *Autoregressive Integrated Moving Average* (ARIMA) digunakan untuk menganalisis dinamika temporal penyebaran COVID-19 di seluruh dunia dalam rentang waktu 22 Januari 2020 hingga 7 April 2020. Jumlah kumulatif orang yang terkonfirmasi positif Covid-19 dan Perkiraan pasien yang terkena dampak Covid-19 selama tiga bulan adalah antara 9,189,262–14,906,483 di seluruh dunia. Nilai prediksi pasien yang terkena dampak Covid 19 ini hanya akan valid jika situasinya tidak berubah, dan epidemi menyebar sesuai dengan sifat sebelumnya di seluruh dunia dalam tiga bulan ini.

Penelitian yang dilakukan oleh Dave et al. (2021) dengan judul "*Forecasting Indonesia Exports using a Hybrid Model ARIMA-LSTM*". Dalam penelitian ini, model hibrida baru untuk peramalan indeks harga saham berjangka bernama WT-ARIMA-LSTM diusulkan. Dalam model hibrida ini, indeks harga saham berjangka didekomposisi untuk mengekstraksi karakteristik data pada skala waktu yang berbeda melalui transformasi wavelet dan model ARIMA-LSTM diterapkan untuk memprediksi harga penutupan berjangka. Temuan penelitian ini adalah sebagai berikut. 1) Model hibrid DWT dan model hybrid MODWT memiliki akurasi peramalan yang lebih tinggi dibandingkan beberapa model peramalan yang umum digunakan berdasarkan tiga metrik MAE, MAPE, dan RMSE. Model DWT-ARIMA-LSTM memiliki kinerja peramalan yang lebih baik ketika kinerja peramalan di pasar yang berbeda dan efisiensi operasional metode tersebut digabungkan. 2) Metode DWT lebih dapat diterapkan dibandingkan metode MODWT dalam model peramalan rangkaian harga penutupan berjangka; perkiraan sinyal yang diperoleh dari dekomposisi DWT memiliki volatilitas yang lebih rendah dan dapat mengkarakterisasi sinyal aslinya dengan lebih baik. 3) Model LSTM

memiliki kinerja prediksi yang lebih baik untuk rangkaian sisa yang berderau, sedangkan model ARIMA memiliki kinerja prediksi yang lebih baik untuk sinyal perkiraan yang lebih sedikit noise. 4) Berdasarkan hasil peramalan, dibangun strategi timing trading yang dapat mempertahankan kinerja return yang kuat dalam kondisi pasar yang berbeda, terutama pada sisi risiko dengan keuntungan yang signifikan. Selain itu, penelitian ini mengkaji dampak kejadian tak terduga dari epidemi COVID-19 terhadap kinerja perkiraan model, dan hasilnya menunjukkan bahwa model tersebut dapat beradaptasi dengan struktur data yang berbeda untuk mencapai kinerja perkiraan yang lebih kuat.

Penelitian yang dilakukan oleh Gupta & Kumar (2022) dengan judul “*Two-step daily reservoir inflow prediction using ARIMA-machine learning and ensemble models*”. Penelitian ini bertujuan untuk memenuhi berbagai tujuan ini secara efektif, pengetahuan tentang aliran masuk di dalam *reservoir* sangatlah penting. Selain data historis, prediksi arus masuk di masa depan juga diperlukan khususnya dalam konteks perubahan iklim. Algoritma dua langkah untuk prediksi aliran masuk waduk untuk memungkinkan perencanaan yang cermat dan pelaksanaan operasi waduk harian dengan tetap memperhitungkan variasi historis aliran masuk telah diusulkan. Algoritma yang dikembangkan memperhitungkan pola data masuk historis menggunakan analisis deret waktu bersama dengan variabilitas pola iklim menggunakan prediktor berbeda dalam model pembelajaran mesin. Langkah pertama dalam penelitian ini menggunakan model deret waktu, metode ARIMA untuk memperkirakan arus masuk bulanan, yang kemudian digunakan sebagai target pada langkah kedua untuk memperkirakan arus masuk harian berdasarkan bulan menggunakan dua jenis model ansambel, yaitu rata-rata dan peningkatan. model dalam pembelajaran mesin. Hasil pengujian menunjukkan bahwa baik untuk model bulanan maupun model harian nilai NRMSE dan NMAE pada periode monsun lebih rendah dibandingkan dengan periode non monsun. Model ensemble rata-rata ditemukan memiliki performa lebih baik dibandingkan model ansambel boosting selama jumlah bulan maksimum. Hasil tahunan menunjukkan kesalahan kurang dari 5% antara nilai aktual dan prediksi untuk semua kasus pengujian, yang menunjukkan presisi dalam algoritma yang dikembangkan.

Penelitian yang dilakukan oleh Ji et al. (2019) dengan judul “*Carbon futures price forecasting based with ARIMA-CNN-LSTM model*”. Tujuan dari penelitian ini untuk memperkenalkan model ARIMA-CNN-LSTM untuk memperkirakan harga karbon berjangka. Model ARIMA-CNN-LSTM menggunakan model ARIMA dan struktur jaringan saraf dalam yang menggabungkan lapisan CNN dan LSTM untuk menangkap fitur data linier dan nonlinier. Dalam struktur model ARIMA-CNN-LSTM, ARIMA digunakan untuk menangkap fitur linier. *Convolutional Neural Network* (CNN) digunakan untuk menangkap struktur data hirarki, sedangkan jaringan *Long Short Term Memory* (LSTM) digunakan untuk menangkap ketergantungan jangka panjang dalam data. Evaluasi kinerja komprehensif telah dilakukan dengan menggunakan harga karbon berjangka mingguan. Hasilnya menegaskan bahwa model ARIMA-CNN-LSTM dapat mencapai akurasi prediksi yang lebih baik dibandingkan model benchmark, dalam hal ukuran kinerja *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE).

Penelitian yang dilakukan oleh Kobiela et al. (2022) dengan judul “*ARIMA vs LSTM on NASDAQ stock exchange data*”. Penelitian ini bertujuan untuk membandingkan hasil dari dua model yang sangat berbeda: model statistik (ARIMA) dan model pembelajaran mendalam (LSTM) berdasarkan kumpulan data NASDAQ yang dipilih. Kedua model tersebut digunakan untuk memprediksi harga rata-rata harian atau bulanan dari perusahaan terpilih yang terdaftar di bursa NASDAQ. Penelitian menunjukkan model mana yang berperforma lebih baik dalam hal data masukan yang dipilih, parameter, dan jumlah fitur. Model yang dipilih dibandingkan dengan menggunakan kesalahan kuadrat rata-rata metrik relatif (MSE) dan kesalahan persentase absolut rata-rata (MAPE). Metrik yang dipilih biasanya digunakan dalam masalah regresi. Analisis yang dilakukan menunjukkan model mana yang mencapai hasil lebih baik dengan membandingkan metrik yang dipilih dalam model yang berbeda. Disimpulkan bahwa model ARIMA berkinerja lebih baik daripada model LSTM dalam hal hanya menggunakan satu fitur—nilai harga historis—dan memprediksi lebih dari satu periode waktu, menggunakan parameter p, q dalam rentang 0 hingga 2, pengoptimal Adam, fungsi aktivasi tanh, dan arsitektur lapisan 2xLSTM. Semakin lama periode jendela data,

semakin baik kinerja ARIMA, dan semakin buruk kinerja LSTM. Perbandingan model dilakukan dengan membandingkan nilai error MAPE. Saat memprediksi 30 hari, ARIMA sekitar 3,4 kali lebih baik dari LSTM. Saat memprediksi rata-rata 3 bulan, ARIMA sekitar 1,8 kali lebih baik dibandingkan LSTM. Saat memperkirakan rata-rata 9 bulan, ARIMA sekitar 2,1 kali lebih baik dibandingkan LSTM.

Penelitian yang dilakukan oleh Krishnamoorthy et al. (2024) dengan judul “*Learned prediction of cholesterol and glucose using ARIMA and LSTM models – A comparison*”. Penelitian ini memiliki tujuan utama untuk menciptakan sistem pemantauan dan perkiraan glukosa dan kolesterol non-invasif yang memanfaatkan kecerdasan buatan dan komputasi *cloud*. Fokus spesifiknya adalah membandingkan efisiensi prediksi dua model: model *Auto-Regressive Integrated Moving Average* (ARIMA) dan model *Long Short-Term Memory* (LSTM). Metodologi penelitian ini melibatkan pengembangan *prototype* perangkat keras untuk pengukuran glukosa dan kolesterol non-invasif, menggunakan sensor *Near Infra-Red* (NIR). Data kadar glukosa dan kolesterol dikumpulkan dan disimpan dari pasien selama jangka waktu satu bulan. Data yang dikumpulkan digunakan untuk melatih model ARIMA dan LSTM. Model dievaluasi menggunakan *Root Mean Square Error* (RMSE), dan akurasi prediksinya dibandingkan. Temuan penelitian mengungkapkan bahwa model ARIMA melampaui model LSTM dalam memprediksi kadar glukosa dan kolesterol. Hal ini didukung oleh RMSE model ARIMA yang lebih rendah (sekitar 71,7 % lebih rendah untuk glukosa dan 50,3 % lebih rendah untuk kolesterol) dibandingkan dengan model LSTM, yang menunjukkan akurasi prediksi yang lebih tinggi. Selain itu, *prototype* perangkat keras ini memfasilitasi pengukuran dan perkiraan non-invasif, memberikan solusi yang menjanjikan untuk meningkatkan diagnosis dan pemantauan dini. Penelitian ini menyoroti potensi model ARIMA dan LSTM dalam aplikasi perawatan kesehatan dan diagnostik. Performa superior model ARIMA dalam memprediksi kadar glukosa dan kolesterol menjadikannya alat yang berharga untuk aplikasi *real-time*. Studi ini memberikan solusi terpadu untuk pengukuran dan perkiraan non-invasif, yang bertujuan untuk meningkatkan diagnosis dini dan pemantauan diabetes dan risiko kardiovaskular.

Penelitian yang dilakukan oleh Li et al. (2023) dengan judul “*Self-paced ARIMA for robust time series prediction*”. penelitian ini bertujuan untuk memprediksi deret waktu, model rata-rata pergerakan terintegrasi autoregresif (ARIMA) adalah salah satu model linier paling klasik dan populer, dan aplikasi yang diperluas telah mencapai akurasi prediksi yang memuaskan di banyak domain. Namun, lebih sedikit pekerjaan yang berfokus pada pengaruh data yang berisik, yang menyebabkan ketidakstabilan ARIMA dan penurunan kinerja yang tajam. Dalam makalah ini, kami mengusulkan kerangka prediksi deret waktu yang kuat bernama spARIMA. Untuk mengurangi gangguan kebisingan dalam proses pelatihan, kami merancang skema pelatihan berurutan dalam batch berdasarkan tingkat kebisingan dan kontribusi terhadap pemodelan yang benar. spARIMA mengandalkan model prediksi diferensial di ARIMA dan menyerap keunggulan skema pelatihan bertahap dalam pembelajaran mandiri (SPL) sehingga spARIMA dapat secara efektif mengatasi ketidakstabilan yang disebabkan oleh kebisingan. Selain itu, mengingat kesamaan sampel yang dipilih dapat menghasilkan solusi optimal lokal, kami memperluas spARIMA ke pemilihan keragaman, yang menggunakan ekspresi jarak kompleksitas-kesamaan lokal yang tertimbang untuk mewakili keragaman data yang berisik. Kami menguji kinerja spARIMA pada dua belas kumpulan data dibandingkan dengan model ARIMA yang ada pada dua algoritma penurunan gradien. Hasilnya menunjukkan bahwa metode kami tidak hanya cocok untuk data yang berisik tetapi juga efisien untuk data normal, yang menunjukkan kemampuan generalisasi spARIMA.

Penelitian yang dilakukan oleh Luo & Gong (2023) dengan judul “*Air pollutant prediction based on ARIMA-WOA-LSTM model*”. Jurnal ini bertujuan untuk memberikan usulan metode untuk memprediksi polutan udara secara akurat dengan tujuan memastikan efisiensi pengelolaan polusi udara. Model ARIMA-WOA-LSTM yang diusulkan menggunakan ARIMA untuk mengekstrak bagian linier dari data polusi udara dan mengeluarkan bagian nonlinier, sedangkan model WOA-LSTM digunakan untuk memprediksi bagian nonlinier, dimana algoritma *whale* digunakan untuk mencari hyperparameter yang sempurna untuk LSTM, dan tujuan pencariannya mencakup jumlah neuron, kecepatan pembelajaran model, dan panjang *batch*. Untuk membuktikan

keunggulan model yang dikembangkan pada artikel ARIMA-WOA-LSTM dibandingkan dengan ARIMA-LSTM, CEEMDAN-WOA-LSTM, WOA-LSTM, ARIMA, dan LSTM. Hasilnya menunjukkan bahwa kinerja ARIMA-WOA-LSTM lebih baik dibandingkan model lainnya dalam tiga aspek: akurasi prediksi polutan, akurasi prediksi model, dan stabilitas prediksi; model gabungan juga berkinerja jauh lebih baik daripada model tunggal dalam tiga aspek; Algoritma *whale* sangat baik untuk mencari lima *hyperparameter* di LSTM, yang penting untuk pengurangan kesalahan model. Model ARIMA-WOA-LSTM mempunyai referensi yang tinggi dalam pengelolaan pencemaran udara.

Jurnal artikel yang dilakukan oleh Mati et al. (2023) dengan judul “*Incorporating Russo-Ukrainian war in Brent crude oil price forecasting: A comparative analysis of ARIMA, TARMA and ENNReg models*”. Artikel ini bertujuan untuk menyelidiki kinerja tiga model-Autoregressive Integrated Moving Average (ARIMA), Threshold Autoregressive Moving Average (TARMA), dan Evidential Neural Network for Regression (ENNReg)-dalam meramalkan harga minyak mentah Brent, sebuah variabel ekonomi penting yang memiliki dampak signifikan pada perekonomian global. Dengan meningkatnya kompleksitas dinamika harga akibat faktor geopolitik seperti perang Rusia-Ukraina, kami mengkaji dampak penggabungan informasi perang terhadap keakuratan perkiraan model-model ini. Analisis kami menunjukkan bahwa menggabungkan dampak perang dapat meningkatkan keakuratan perkiraan model secara signifikan, dan model ENNReg dengan penyertaan variabel *dummy* mengungguli model lain selama periode perang. Memasukkan variabel perang telah meningkatkan akurasi perkiraan model ENNReg sebesar 0,11%. Hasil-hasil ini membawa implikasi yang signifikan bagi para pembuat kebijakan, investor, dan peneliti yang tertarik untuk mengembangkan model perkiraan yang akurat dalam menghadapi peristiwa geopolitik seperti perang Rusia-Ukraina. Hasilnya dapat digunakan oleh pemerintah negara-negara pengekspor minyak untuk kebijakan anggaran.

Penelitian yang dilakukan oleh Ray et al. (2023) dengan judul “*An ARIMA-LSTM model for predicting volatile agricultural price series with random forest technique*”. Penelitian ini bertujuan pada penyajian algoritma pembelajaran mesin dengan perhatian

khusus pada model pembelajaran mendalam dalam bentuk alternatif potensial untuk model statistik seperti model *Autoregressive Integrated Moving Average* (ARIMA) dan model *ARIMA-Generalised Autoregressive Conditional Heteroscedasticity* (GARCH). Selanjutnya, model hibrid *ARIMA-Long Short-Term Memory* (LSTM) yang lebih baik berdasarkan kriteria pemilihan kelambatan hutan secara acak telah diperkenalkan. Model ARIMA telah digunakan untuk memperkirakan efek rata-rata dan model GARCH digunakan dengan residu yang diperoleh dari model ARIMA untuk memperkirakan perilaku volatil dari rangkaian tersebut. Model ARIMA-GARCH bertindak sebagai model statistik yang lebih unggul dibandingkan model ARIMA berdasarkan nilai AIC dan BIC terendah. Model LSTM digunakan pada semua seri data pelatihan yang dinormalisasi. Setelah itu penelitian ini membangun skenario perbandingan secara mandiri antara model ARIMA, ARIMA-GARCH, LSTM dan ARIMA-LSTM mengenai akurasi peramalan dalam hal nilai RMSE, MAPE dan MASE terendah. Usulan model acak berbasis hutan ARIMA-LSTM membuktikan keunggulannya dibandingkan model statistik konvensional dengan peningkatan sebesar 8–25% untuk RMSE, 2–28% untuk MAPE, dan 2–29% untuk MASE.

Berikut merupakan rangkuman kajian literatur yang dijelaskan di atas dari penelitian terdahulu dengan penelitian yang dilakukan dalam tabel 2.1 di bawah ini.

Tabel 2. 1 Penelitian Terdahulu

No	Penulis (Tahun)	Judul	Sektor Industri	Metode Pengolahan Data	
				ARIMA	EMA
1	K. E. ArunKumar, Dinesh V. Kalaga, Ch. Mohan Sai Kumar, Masahiro Kawaji, & Timothy M. Brenza (2022)	<i>Comparative analysis of Gated Recurrent Units (GRU), Exponential Moving Average (EMA) cells, autoregressive Integrated moving average (ARIMA), seasonal autoregressive Integrated moving average (SARIMA) for forecasting COVID-19 trends</i>	Kesehatan	√	√
2	Fuad Ahmed Chyon, Md. Nazmul Hasan Suman, Md. Rafiul Islam Fahim, & Md. Sazol Ahmmed (2022)	<i>Time series analysis and predicting COVID-19 affected patients by ARIMA model using machine learning</i>	Kesehatan	√	
3	Emmanuel Dave, Albert Leonardo, Marethia Jeanice, & Novita Hanafiah (2021)	<i>Forecasting Indonesia Exports using a Hybrid Model ARIMA-Exponential Moving Average (EMA)</i>	Ekonomi	√	√
4	Akshita Gupta & Arun Kumar (2022)	<i>Two-step daily reservoir inflow prediction using ARIMA-machine learning and ensemble models</i>	Lingkungan	√	
5	Lei Ji, Yingchao Zou, Kaijian He, & Bangzhu Zhu (2019)	<i>Carbon futures price forecasting based with ARIMA-CNN-EMA model</i>	Lingkungan	√	√
6	Dariusz Kobiela, Dawid Krefta, Weronika Krol, & Pawet Weichbroth (2022)	<i>ARIMA vs EMA on NASDAQ stock exchange data</i>	Ekonomi	√	√

No	Penulis (Tahun)	Judul	Sektor Industri	Metode Pengolahan Data	
				ARIMA	EMA
7	Umapathi Krishnamoorthy, V. Karthika, M. K. Mathumitha, Hitesh Panchal, Vijay Kumar S. Jatti, & Abhinav Kumar (2024)	<i>Learned prediction of cholesterol and glucose using ARIMA and EMA models – A comparison</i>	Kesehatan	√	√
8	Yitong Li, Kai Wu, & Jing Liu (2023)	<i>Self-paced ARIMA for robust time series prediction</i>	Lingkungan & Ekonomi	√	
9	Jun Luo & Yaping Gong (2023)	<i>Air pollutant prediction based on ARIMA-WOA- EMA model</i>	Distributor	√	√
10	Sagiru Mati, Magdalena Radulescu, Najia Saqib, Ahmed Samour, Goran Yousif Ismael, & Nazifi Aliyu (2023)	<i>Incorporating Russo- Ukrainian war in Brent crude oil price forecasting: A comparative analysis of ARIMA, TARMA and ENNReg models</i>	Ekonomi	√	
11	Soumik Ray, Achal Lama, Pradeep Mishra, Tufleuddin Biswas, Soumitra Sankar Das, & Bishal Gurung (2023)	<i>An ARIMA-EMA model for predicting volatile agricultural price series with random forest technique</i>	Lingkungan	√	√
12	Muhammad Tri Rahffi (2024)	Implementasi <i>Machine Learning</i> Dalam Memprediksi Jumlah Pendonor Darah Dengan Menggunakan Model ARIMA dan EMA (Studi Kasus PMI Sleman)	Kesehatan	√	√

2.2 Landasan Teori

2.2.1 *Machine Learning*

Menurut Shwartz dan David (2004), *machine learning* merupakan Pembelajaran mesin adalah studi algoritma yang digunakan untuk mempelajari sesuatu untuk melakukan tugas tertentu yang ditentukan oleh manusia secara otomatis. Tujuan dari pembelajaran mesin adalah untuk membuat sistem yang dapat memahami algoritma sehingga dapat melakukan tugas mandiri secara otomatis yang biasanya dilakukan oleh manusia. Alat mesin pembelajaran telah banyak digunakan dalam kehidupan sehari-hari, seperti pengenalan wajah (sistem yang dapat mengenali wajah seseorang), pemahaman suara (sistem pemrosesan untuk mengubah suara menjadi teks tulisan) dan Bagi konsumen (sistem yang menganalisis pola perilaku konsumen untuk membantu produsen dalam pemasaran). Berdasarkan konsep pembelajarannya *machine learning* dibagi menjadi 2 jenis, yaitu:

1. *Surprised Learning*

Surprised learning merupakan teknik pembelajaran mesin untuk meramalkan peristiwa dimasa yang akan datang berdasarkan data yang diperoleh dari masa lalu/lampau dengan membuat suatu fungsi berdasarkan data tersebut.

2. *Unsuprised Learning*

Unsuprised learning merupakan teknik pembelajaran mesin dengan membuat gambaran pola berdasarkan data yang sudah ada sebelumnya, pada teknik ini tidak adanya pengklasifikasian data namun mencari struktur tersembunyi dari data input tersebut.

2.2.2 Data

Williams & Sawyer (2007) mengatakan bahwa data adalah kumpulan informasi yang berisi fakta dan angka. Selain itu, Mulyanto (2009) mengatakan bahwa data adalah bahan mentah yang berisi peristiwa, konsep, manusia, hewan, dan lain-lain dalam bentuk kata, angka, gambar, atau media lainnya sebagai representasi dari peristiwa yang perlu diolah lebih lanjut untuk mendapatkan informasi. Ada dua jenis data yang dapat diklasifikasikan

sebagai data kuantitatif dan kualitatif. Untuk itu, data dapat diklasifikasikan menjadi beberapa golongan antara lain sebagai berikut:

2.2.2.1 Klasifikasi Berdasarkan Sifat Data

a. Sikrit data

Sikrit data adalah data yang biasanya diperoleh dari hasil penghitungan dan didefinisikan sebagai data di mana nilai terbatas antara nilai satu dan nilai lainnya. Adapun contohnya: Jumlah pulpen yang dimiliki siswa, jumlah karyawan di perusahaan X, dan jumlah penjualan produk.

b. Kontinu data

Data kontinu adalah data yang biasanya diperoleh dari hasil pengukuran dan didefinisikan sebagai data yang nilainya tidak terbatas pada kisaran tertentu. Contohnya adalah data suhu badan yang diukur dengan termometer, diameter cincin yang diukur dengan jangka sorong, dan berat badan yang diukur dengan timbangan.

2.2.2.2 Klasifikasi Berdasarkan Waktu Pengumpulannya

a. Data *Cross Section*

Data *cross-section* adalah data yang dikumpulkan pada titik waktu tertentu. Ini berarti bahwa data tidak dikumpulkan pada satu titik waktu tertentu. Contohnya adalah data konsumen PT XYZ pada bulan Mei 2020.

b. Data *Time Series*

Data *time series* adalah data yang dikumpulkan sepanjang waktu atau periode sebelumnya. Contoh: Data penjualan bulan Mei 2020 – Mei 2021

2.2.3 *Time Series*

Time series merupakan metode peramalan yang mengasumsikan bahwa masa depan merupakan fungsi dari masa lalu (Heizer & Render, 2009). Hal ini sesuai dengan tujuan metode *time series* yaitu pola dianalisis berdasarkan rangkaian data historis. Pengamatan *time series* menggunakan data dari lokasi yang sama secara berurutan dan pada interval waktu tertentu. Interval yang digunakan bisa minggu, bulan ataupun tahun. Umumnya terdapat beberapa jenis *time series*, yaitu (Hanke & Wichern, 2005):

a. Pola Siklus

Pola yang dapat mengalami fluktuasi dari data yang memiliki jangka waktu lebih dari satu tahun.

b. Pola Trend

Pola yang berfokus terhadap arah data dalam jangka panjang, dapat juga berupa kenaikan maupun penurunan.

c. Pola Horizontal

Pola yang berasal dari peristiwa tidak terduga dan bersifat acak namun keberadaannya dapat mempengaruhi fluktuasi data *time series*.

d. Pola Musiman

Pola yang mengalami fluktuasi disebabkan data yang periodik dalam kurun waktu kurang dari satu tahun.

2.2.4 Stasioneritas

Menurut Brillinger (2005), salah satu asumsi untuk memprediksi data *time series* adalah data tersebut harus stasioner. Stasioneritas adalah peristiwa yang menambah atau mengurangi pengalaman data. Datanya akan jadi kalau model datanya tidak elegan, tidak berbeda dari waktu ke waktu, selalu berbeda (Marvillia, 2013). Untuk memeriksa stasioneritas data, dapat melakukannya menggunakan plot data. Pada plot data, jika terjadi naik turun dari lag pertama ke ekstrim berikutnya, maka akan pecah dan data deret waktu akan tetap utuh. Namun pengecekan metode dengan melihat area data bersifat subyektif. Untuk menentukan stasioneritas data dengan akurat dapat menggunakan uji *Augmented Dickey-Fuller* (uji ADF). Apabila data anda mengandung nonstasioner, maka cara mengubah data nonstasioner menjadi data stasioner adalah dengan mencari perbedaannya (Marvillia, 2013).

2.2.5 Autoregressive Integrated Moving Average (ARIMA)

Metode ARIMA (*Autoregressive Integrated Moving Average*) merupakan metode yang dikembangkan oleh Box dan Jenkins pada tahun 1976. ARIMA merupakan salah satu algoritma dari *machine learning* untuk data historis, model ini mengabaikan variabel independen dan model ini tidak mengambil model tertentu (Lubis et al., 2019). Dalam

penggunaannya, model ini dapat digunakan dalam *time series* yang stasioner. Metode ARIMA merupakan kombinasi *autoregressive* (AR) dan *moving average* (MA) (Hanke & Wichern, 2005).

1. *Autoregressive* (AR)

Bentuk khusus dari model *autoregressive* dan AR(p) atau model ARIMA (p, 0, 0) seperti berikut:

$$Y_t = \theta_0 + \theta_1 Y_{t-1} + \dots + \theta_p Y_{t-p} + \varepsilon_t$$

2. *Moving Average* (MA)

Bentuk khusus dari model *Moving Average* dengan MW(q) atau mode ARIMA (0, 0, q) seperti berikut:

$$Y_t = \mu + \varepsilon_t - \omega_1 \varepsilon_{t-1} - \dots - \omega_q \varepsilon_{t-q}$$

3. *Autoregressive* dan *Moving Average* (ARMA)

Bentuk khusus gabungan yang dinyatakan sebagai berikut:

$$Y_t = \theta_0 + \theta_1 Y_{t-1} + \dots + \theta_p Y_{t-p} + \varepsilon_t - \omega_1 \varepsilon_{t-1} - \dots - \omega_q \varepsilon_t$$

2.2.6 *Exponential Moving Average* (EMA)

Exponential Moving Average (EMA) adalah metode penghitungan rata-rata pergerakan harga atau data dalam suatu rentang waktu tertentu, dengan memberikan bobot yang lebih besar pada data yang lebih baru (Utami et al., 2022). EMA termasuk algoritma *Q-Learning* salah satu jenis turunan *machine learning*. *Q-Learning* adalah algoritma dalam *rainforment learning* yang merupakan turunan dari *manchine learning* (Hardini, n.d., 2019). Dalam analisis teknis pasar ke prediksi, EMA adalah salah satu indikator yang sering digunakan untuk mengidentifikasi tren pasar dan membantu para trader dalam pengambilan keputusan. Pada EMA, data yang lebih baru diberi bobot yang lebih besar. Bobot tersebut dihitung menggunakan faktor penghalus (*smoothing factor*) yang berada dalam rentang 0 hingga 1. Semakin besar nilai faktor penghalus, semakin tinggi bobot yang diberikan pada data terbaru. Berikut rumus umum dalam mengitung data menggunakan EMA:

$$EMA(t) = (Data(t) - EMA(t-1)) \times \alpha + EMA(t-1)$$

Keterangan:

$EMA(t)$: nilai EMA pada periode waktu t

$Data(t)$: data pendonor pada periode waktu t

$EMA(t-1)$: nilai EMA pada periode sebelumnya

α : faktor penghalus, yang biasanya dihitung sebagai $2 / (n+1)$ dimana n adalah jumlah periode yang dipilih

2.2.7 Pengujian Tingkat Error

Pengukuran terjadinya kesalahan dalam peramalan dikarenakan adanya perbedaan dengan peramalan aktual dengan peramalan permintaan (Taylor, 2004). Menurut Preswitch dkk. (2014), dalam pengukuran tingkat kesalahan ada beberapa macam metodenya, pengukuran yang bisa diterapkan untuk mengukur kesalahan peramalan, sebagai berikut:

2.2.7.1 Scale Dependent Measure

1. Mean [Signed] Error (ME)

$$\text{Mean} (e_t)$$

$$e_t = y_t - \hat{y}_t$$

2. Mean Square Error (MSE)

$$\text{Mean}(e_t^2)$$

3. Root-Mean Square Error (RMSE)

$$\sqrt{\text{MSE}}$$

4. Mean Absolute Error (MAE)

$$\text{Mean} (|e_t|)$$

5. Median Absolute Error (MdAE)

$$\text{Median} (|e_t|)$$

2.2.7.2 Percentage Measure

1. Mean Absolute Percentage Error (MAPE)

$$\text{Mean} (|p_t|)$$

$$p_t = \frac{100 e_t}{y_t}$$

2. *Median Absolute Percentage Error (MdAPE)*

$$\text{Median}(|p_t|)$$

3. *Root-Mean Square Percentage Error (RMSPE)*

$$\sqrt{\text{Mean}(p_t^2)}$$

4. *Root-Median Square Percentage Error (RMdSPE)*

$$\sqrt{\text{Median}(p_t^2)}$$

5. *Symmetric Mean Absolute Percentage Error (sMAPE)*

$$\text{Mean} \left(\frac{200|e_t|}{y_t - \hat{y}_t} \right)$$

6. *Symmetric Median Absolute Percentage Error (sMdAPE)*

$$\text{Median} \left(\frac{200|e_t|}{y_t - \hat{y}_t} \right)$$

BAB III

METODE PENELITIAN

3.1 Objek Penelitian

Objek penelitian kali ini adalah prediksi jumlah pendonor darah di PMI Sleman dengan mengimplementasikan *machine learning* menggunakan model *autoregressive integrated moving average* (ARIMA) dan *Exponential moving average* (EMA). PMI Sleman salah satu pelayan kesehatan sebagai *supply* darah dan penampungan darah yang berguna bagi kesehatan masyarakat. PMI Sleman berada di Jalan Radjiman, Sucen, Triharjo, Kecamatan Sleman, Kabupaten Sleman, Daerah Istimewa Yogyakarta 55514.

3.2 Pengumpulan Data

Pengumpulan data pada penelitian kali ini dilakukan seperti berikut:

1. Data Primer

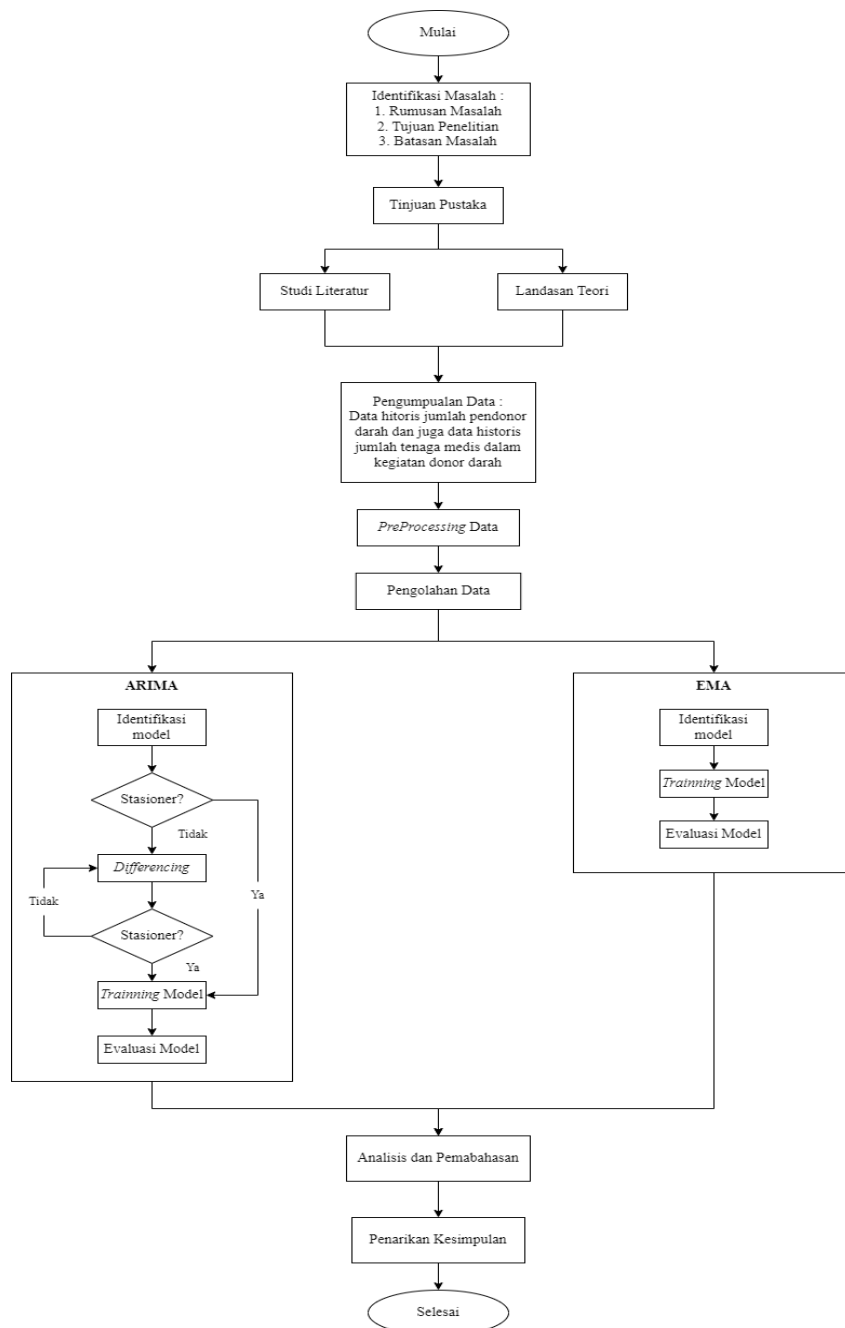
Data diambil secara wawancara kepada pihak bersangkutan di PMI Sleman, Yogyakarta. Wawancara ini bertujuan untuk menggali informasi mengenai sistem tenaga medis dalam menangani jumlah pendonor darah di PMI Sleman. Setelah berdiskusi dilanjutkan dengan mengikuti kegiatan donor darah guna menganalisa setiap proses donor darah, mulai dari segi waktu penanganan donor darah sampai penanganan tiap tenaga medis untuk beberapa pendonor darah.

2. Data Sekunder

Data yang digunakan sebagai pendukung dalam penelitian dan diperoleh secara tidak langsung merupakan data sekunder. Biasanya, data sekunder diambil dari jurnal, buku, atau sumber literatur lainnya. Dalam konteks penelitian ini, data sekunder juga mencakup dokumen-dokumen atau arsip perusahaan yang terkait dengan topik penelitian. Data historis jumlah pendonor darah setiap kegiatan donor darah di PMI Sleman adalah data sekunder yang dioleh sebagai acuan dalam penelitian ini.

3.3 Alur Penelitian

Alur penelitian dapat menunjukkan proses yang di dalam penelitian dengan menggunakan diagram alur. Gambar 3.1 dapat dilihat diagram alurnya mulai dari identifikasi masalah hingga penarikan kesimpulan.



Gambar 3. 1 *Flowchart* Alur Penelitian

Berdasarkan *flowchart* diagram alur penelitian (gambar 3.1) dapat dijelaskan tahapan dalam melakukan penelitian “Implementasi *Machine Learning* Dalam Memprediksi Jumlah Kebutuhan Tenaga Medis dengan Menggunakan Model ARIMA Pada PMI Kabupaten Sleman”.

1. Mulai

Tahap dimulai dengan mempelajari tentang apa yang akan diteliti sebelum dilanjutkan ke identifikasi masalah di PMI Kabupaten Sleman.

2. Identifikasi Masalah

Penelitian diawali dengan melihat dan meneliti kondisi perusahaan secara langsung dan melibatkan PMI untuk mengidentifikasi permasalahan terkait jumlah pendonor darah, serta memprediksi untuk kedepannya.

3. Tinjauan Pustaka

Tinjauan Pustaka merupakan bagian penting dalam penelitian karena digunakan sebagai referensi dan rangkuman dalam penelitian, berdasarkan studi sebelumnya. Tinjauan Pustaka dibagi menjadi dua bagian, yaitu:

- a. Studi Literatur

Studi literatur proses menyelidiki dan menganalisis literatur atau karya-karya tulis yang relevan dengan topik yang terkait.

- b. Landasan Teori

Landasan teori mencakup definisi konsep-konsep yang relevan dengan penelitian. Ini membantu memastikan bahwa istilah-istilah yang digunakan dalam penelitian memiliki makna yang jelas.

4. Pengumpulan Data

Pengumpulan data dilakukan dengan data primer dan sekunder. Untuk data primer dilakukan dengan observasi langsung ke PMI Kabupaten Sleman dan berdiskusi langsung dengan pihak yang berwenang untuk data yang ingin diolah. Untuk data sekunder didapatkan dari kajian yang terdahulu serta data historis PMI Kabupaten Sleman, data permasalahan yang berkaitan dengan jumlah pendonor darah tiap kegiatan donor darah sesuai kebutuhan data penelitian.

5. *Preprocessing* Data

Pre-processing data adalah langkah-langkah yang digunakan sebagai bentuk proses penemuan pengetahuan yang di dasarkan data yang berkualitas (Zahara & Sugianto, 2021). Tahap ini termasuk tahap yang penting dalam analisis data dan pembelajaran mesin yang melibatkan pembersihan, transformasi, dan penyusunan data mentah menjadi format yang lebih cocok untuk analisis lebih lanjut atau pelatihan model. Tujuan dari *pre-processing* adalah untuk meningkatkan kualitas data dan memastikan bahwa model yang digunakan dapat menghasilkan hasil yang akurat dan andal. *Pre-processing* data dilakukan untuk mempersiapkan data sebelum dilakukan pemodelan prediksi.

6. Pengolahan Data

Pengolahan data dilakukan dengan menggunakan bahasa pemrograman Rstudio. RStudio merupakan lingkungan pengembangan terintegrasi (Integrated Development Environment atau IDE) yang khusus dirancang untuk bahasa pemrograman R. Ini menyediakan berbagai fitur yang memudahkan pengembangan, analisis data, visualisasi, dan penulisan kode dalam bahasa R. RStudio menyediakan lingkungan yang kuat dan fleksibel untuk melakukan analisis data, pemodelan, dan peramalan.

7. Pemodelan ARIMA dan EMA

Pada penelitian ini dilakukan menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) dan *Exponential Moving Average* (EMA) untuk memecahkan permasalahan dan memberi Solusi. Model ARIMA merupakan salah satu metode yang umum digunakan untuk analisis deret waktu dalam statistik dan ekonometri. Model ARIMA digunakan untuk meramalkan nilai-nilai masa depan dari suatu deret waktu berdasarkan pola historis yang teridentifikasi dalam data (Fauzani & Rahmi, 2023). Pada penelitian kali ini ada tahap yang harus diperhatikan terlebih dahulu dalam menggunakan model ARIMA diantaranya, identifikasi model, differencing, estimasi parameter model dan training model.

EMA merupakan salah satu metode perataan data dalam analisis deret waktu. Ini adalah teknik yang digunakan untuk meratakan atau menyesuaikan data dengan memberikan bobot yang berbeda pada nilai-nilai dalam deret waktu. Dalam

Exponential Moving Average, bobot yang diberikan pada setiap observasi berkurang secara eksponensial seiring berjalannya waktu. Dengan kata lain, nilai lebih baru dalam deret waktu diberi bobot yang lebih besar daripada nilai yang lebih lama. Pada peramalan kali dilakukan identifikasi model terlebih dahulu lalu dapat agar sesuai dengan data yang di olah, setelah itu *training* model untuk dapat mengetahui hasil permalan.

8. Pengujian Tingkat Error

Pengujian tingkat error bertujuan untuk membandingkan, mengawasi, dan memastikan model peramalan dapat menjadi Solusi permasalahan. Metode yang digunakan untuk pengujian tingkat error adalah Mean Absolute Percentage Error (MAPE). MAPE merupakan persentase absolut kesalahan antara nilai aktual dan nilai prediksi.

9. Analisis dan Pembahasan

Setelah data diolah, selanjutnya ketahap analisis dan pembahasan untuk setiap proses model ARIMA. Selain itu, analisis perbaikan dan Solusi untuk kinerja tenaga medis yang diperlukan dalam kegiatan donor darah di PMI Kabupaten Sleman.

10. Penarikan Kesimpulan

Penelitian ini diakhiri dengan mengambil kesimpulan dari analisis data guna menjawab pertanyaan penelitian dan mencapai tujuan penelitian yang telah ditetapkan. Selanjutnya, disampaikan saran dalam bentuk pertimbangan dan rekomendasi untuk perbaikan pada penelitian yang akan datang. Hal ini dilakukan untuk memberikan arahan yang konstruktif dan memberikan kontribusi pada pengembangan penelitian di masa mendatang.

BAB IV

PENGUMPULAN DAN PENGOLAHAN DATA

4.1 Pengumpulan Data

Pada penelitian kali ini, data yang digunakan merupakan data sekunder, yaitu data historis jumlah pendonor darah pada setiap kegiatan donor darah yang dilakukan oleh PMI Kabupaten Sleman. Pengumpulan data dilakukan dengan menghubungi divisi yang expert dalam perekapan data historis kegiatan donor darah. Pengunduhan data dilakukan pada data historis 1 Oktober 2023 – 31 Desember 2023 dalam format xlsx. Total data yang dikumpulkan 4.258 data historis jumlah pendonor. Terdapat 2 entitas data dengan 2 deskripsi yang terdapat dalam *database* tersebut, diantaranya sebagai berikut:

Tabel 4. 1 Entitas Data

No	Entitas	Deskripsi
1	Waktu	Tanggal kegiatan donor darah.
2	Permintaan darah	Jumlah pendonor dalam kegiatan donor darah.

Tanggal	Nama
01/10/2023 09:02	Didi Sunandar
01/10/2023 09:03	Hery Sugiharto
01/10/2023 09:05	Radius Hendrawan
01/10/2023 09:07	Daniel Yusak Agustinus
01/10/2023 09:09	Laurencia Lintang Arum Purbasari Harjanto
01/10/2023 09:10	Lusiana Dewi Andoko
01/10/2023 09:14	Parmin
01/10/2023 09:16	Handayani Indra Astuti
01/10/2023 09:18	Ema Mariyana
01/10/2023 09:21	Ferry Wahyu Wibowo
01/10/2023 09:27	Evi Yulianti
01/10/2023 09:29	Timbul Sunoto
01/10/2023 09:29	Sugeng Raharjo
01/10/2023 09:33	Sri Hayatun Wahyuni
01/10/2023 09:35	Hayu Widyadi

Gambar 4.1 Data Historis Jumlah Pendonor

4.2 *Pre-Processing Data*

Pre-processing data merupakan proses yang dilakukan untuk membersihkan, mengubah, memanipulasi, atau mengorganisir data agar dapat diolah lebih lanjut atau dieksplorasi dengan lebih baik. Ini adalah tahap awal dalam analisis data di mana data mentah atau tidak terstruktur diubah menjadi bentuk yang lebih berguna atau terstruktur. *Pre-processing* pada penelitian dilakukan menggunakan *Software Microsoft Excel* dengan menjumlah banyaknya pendonor darah per harinya agar data tersebut dapat dideteksi sebagai *time series* kemudian analisis yang dilakukan menggunakan *Software R-Studio* dengan menggunakan beberapa *packages*, yaitu:

1. *tseries: packages* ini menyediakan berbagai fungsi untuk melakukan analisis statistik dan ekonometri pada data deret waktu, termasuk uji stasioneritas, identifikasi pola musiman, dan estimasi model ARIMA. *Packages* tersebut digunakan untuk menjalankan uji-uji statistik terkait deret waktu seperti uji ADF (*Augmented Dickey-Fuller*) untuk stasioneritas.
2. *forecast: packages* ini menyediakan berbagai fungsi dan algoritma untuk memodelkan data deret waktu dan menghasilkan perkiraan atau prediksi di masa depan. *Packages* tersebut digunakan untuk membuat model ARIMA, model musiman, atau model lainnya untuk peramalan data deret waktu.
3. *ggplot2: packages* ini memungkinkan pembuatan berbagai jenis grafik, termasuk scatter plots, line plots, bar plots, dan masih banyak lagi, dengan fleksibilitas dalam menyesuaikan tampilan grafik. *Packages* tersebut digunakan untuk membuat visualisasi data yang menarik.
4. *quantmod: packages* ini digunakan dalam analisis keuangan, terutama dalam mengambil data keuangan dari berbagai sumber, melakukan analisis teknis, dan memvisualisasikan data keuangan.
5. *TTR: packages* ini digunakan untuk menyediakan berbagai indikator teknis yang digunakan dalam analisis teknis dan perdagangan saham.

4.2.1 *Persiapan Data*

Persiapan data dalam hal ini dilakukan untuk menyiapkan data *training* dan data *testing* sebelum masuk ke dalam pemodelan. Pembagian data *training* dan data *testing*

yang akan digunakan dengan komposisi data *training* 90% dan data *testing* 10%. Sebelum melakukan pembagian data, peneliti akan memanggil data yang telah dilakukan *pre-processing*. Kemudian untuk mengambil data Jumlah Pendonor, setelah itu mengubahnya menjadi data *time series* dengan “data.ts” adalah nama dari objek.

```
data <- read.csv(file.choose(),header=T,sep=";")
data.ts = ts(data$Jumlah_Pendonor, start = c(2023,10), freq = 365.6)
ts.plot(data.ts)
adf.test(data.ts)
#menggunakan train 70 dan 80% tidak bisa karena acf dan pacf tidak ada yg signifikan
# Data train dan test dg rasio 90%:10%
n = round(0.1*NROW(data.ts), 0)
n
train = window(data.ts[1:67])
train
test = window(data.ts[68:75])
test
adf.test(train)
```

Gambar 4.2 Syntax Memanggil Data

4.3 Pemodelan ARIMA

Metode ARIMA (*Autoregressive Integrated Moving Average*) merupakan metode analisis deret berkala yang dikenal sebagai Box Jenkins. Metode ini berasal dari penggabungan antara model *Autoregressive* (AR) dan *Moving Average* (MA). Asumsi kestasioneran merupakan asumsi yang harus dipenuhi dalam memodelkan runtun waktu. Deret non stasioner dapat ditransformasikan ke dalam deret stasioner dengan cara pembedaan (*differencing*). Ketidak-stasioneran dalam runtun waktu dapat meliputi mean yang tidak konstan, varians yang tidak konstan ataupun keduanya (*mean* dan varians tidak konstan).

4.3.1 Identifikasi Model

Langkah pertama dalam pemodelan ARIMA adalah identifikasi model. Ini dilakukan untuk mengetahui stasioneritas kondisi data seri waktu yang akan digunakan untuk pemodelan prediksi. Hal ini dilakukan dengan melakukan *Test Dickey-Fuller* yang diperluas (ADF). Perbandingan nilai p pada hasil tes *Test Dickey-Fuller* (ADF) dengan nilai α (0,05) dilakukan untuk mengetahui stasioneritas data. Jika nilai p-value kurang dari α , maka data tidak memiliki unit akar, atau dianggap sudah stasioner. Sebaliknya,

jika nilai p -value lebih besar dari α , maka data memiliki unit akar, atau dianggap tidak stasioner.

```
data.ts = ts(data$Jumlah_Pendonor, start = c(2023,10), freq = 365.6)
ts.plot(data.ts)
#menggunakan train 70 dan 80% tidak bisa karena acf dan pacf tidak ada yg signifikan
# Data train dan test dg rasio 90%:10%
n = round(0.1*NROW(data.ts), 0)
n
train = window(data.ts[1:67])
train
test = window(data.ts[68:75])
test
adf.test(data.ts)
adf.test(train)
```

Gambar 4.3 Eksplorasi Data *Time Series*

4.3.2 Differencing

Langkah kedua adalah melakukan perbedaan. Diferensiasi dilakukan karena hasil *Test Dickey-Fuller (ADF) Test*, yang menunjukkan p -value $>$ α (0.05), menunjukkan bahwa data tidak stasioner. *Differencing* adalah proses mengubah data yang tidak stasioner menjadi stasioner dengan menghitung nilai perbedaan antara data yang diamati dan data yang diamati sebelumnya. Setelah *differencing* selesai, *ADF test* diperlukan untuk mengetahui apakah data yang telah dilakukan *differencing* sudah stasioner atau tidak. Berdasarkan hasil yang didapatkan dari uji ADF, diperoleh bahwa p -value lebih kecil dari α (0.05), sehingga peneliti tidak perlu melakukan *differencing*.

Setelah itu peneliti akan melakukan identifikasi model dengan menggunakan *Autocorrelation Function (ACF)* dan *Partial Autocorrelation Function (PACF)* dengan menggunakan jendela grafik baris 1 dan kolom 2.

```
par(mfrow = c(1,2))
Acf(train, lag.max = 20)
Pacf(train, lag.max = 20)
```

Gambar 4.4 Melakukan Identifikasi Model

4.3.3 Estimasi Parameter Model

Langkah ketiga adalah memilih estimasi parameter model ARIMA. Ini dilakukan dengan menggunakan fungsi *Auto ARIMA*, yang secara otomatis akan menemukan

model ARIMA yang tepat. Pada dasarnya, Auto ARIMA menggunakan kriteria pemilihan, yaitu *Akaike Information Criterion* (AIC), untuk memilih model regresi terbaik. Metode kerja Auto ARIMA bergantung pada pendekatan nilai AIC, yaitu dengan melihat nilai AIC yang paling rendah untuk diambil menjadi suatu model parameter (p, d, q).

Selanjutnya peneliti akan membuat dua model estimasi parameter. Pada model pertama yaitu jumlah pendonor darah peneliti menggunakan order (0,0,17), (0,0,16), (0,0,15), (0,0,14), (0,0,13) beserta hasil *summary*.

```
model1 = Arima(train, order = c(0,0,17))
model2 = Arima(train, order = c(0,0,16))
model3 = Arima(data.ts, order = c(0,0,15))
model4 = Arima(data.ts, order = c(0,0,14))
model5 = Arima(data.ts, order = c(0,0,13))
summary(model1)
summary(model2)
summary(model3)
summary(model4)
summary(model5)
```

Gambar 4.5 Membuat Model ARIMA Jumlah Pendonor

Peneliti akan membuat *function* untuk uji signifikansi parameter (uji t) pada model ARIMA yang telah dibuat seperti berikut ini.

```

printstatarima <- function(x, digits = 4, se=T,...){
  if (length(x$coef) > 0) {
    cat("\nCoefficients:\n")
    coef <- round(x$coef, digits = digits)
    if (se && nrow(x$var.coef)) {
      ses <- rep(0, length(coef))
      ses[x$mask] <- round(sqrt(diag(x$var.coef)), digits =
        digits)
      coef <- matrix(coef, 1, dimnames = list(NULL,
        names(coef)))
      coef <- rbind(coef, s.e. = ses)
      statt <- coef[1,]/ses
      pval <- 2*pt(abs(statt), df=length(x$residuals)-1,
        lower.tail = F)
      coef <- rbind(coef, t=round(statt,digits=digits),sign.=round(pval,digits=digits))
      coef <-
        t(coef)
    }
    print.default(coef, print.gap =
      2)
  }
}

printstatarima(model1)
printstatarima(model2)
printstatarima(model3)
printstatarima(model4)
printstatarima(model5)

```

Gambar 4. 6 *Function* Untuk Uji Signifikansi Parameter Model ARIMA

Berdasarkan syntax diatas, function tersebut digunakan untuk untuk mempermudah peneliti dalam menggunakan model yang lebih efektif dalam ARIMA, selanjutnya peneliti dapat langsung menggunakan perintah `printstatarima()` untuk menampilkan ringkasan dari model yang didapatkan.

Setelah itu, peneliti akan melakukan uji diagnostik dan mendefenisikan nilai *fitted* dari model ARIMA yang signifikan, serta melakukan prediksi data testing beserta visualisasi hasil peramalan.

```

tsdiag(model1)
model1$fitted
pred.donor = forecast(model1, h = length(test))
pred.donor=round(pred.donor$mean)
pred.donor1 = forecast(model1, h = 30)
pred.donor1=round(pred.donor1$mean)
plot(pred.donor)

```

Gambar 4. 7 Prediksi Data *Testing* Jumlah Pendonor

Berdasarkan syntax diatas, `tsdiag()` tersebut digunakan untuk melihat signifikansi pada model yang telah dipilih, sehingga dapat menghasilkan hasil peramalan yang lebih akurat.

4.3.4 Evaluasi Model ARIMA

Langkah terakhir adalah melakukan evaluasi terhadap model yang digunakan dengan melakukan pengujian tingkat *error*. Pengukuran akurasi hasil peramalan dilakukan dengan menggunakan metode *Mean Absolute Percentage Error* (MAPE).

```
#mape
#Testing
mape_1 = mean(abs(error)/test)*100
mape_1
```

Gambar 4. 8 Evaluasi Hasil Peramalan dengan MAPE

4.4 Exponential Moving Average (EMA)

Pemberian bobot pada EMA (*Exponential Moving Average*) sama seperti juga pada *Weighted Moving Average*, melibatkan periode Perhitungan EMA dengan panjang periode sebanyak n (dalam studi kasus n adalah periode 2 dikarenakan perbandingan akan dimulai dari data teratas hasil peramalan dan data aktual. Algoritma tersebut dapat dilakukan dengan *syntax* `ema2 = EMA(train, n = length n)`. Dengan kata lain, nilai peramalan satu periode ke depan, sama dengan nilai peramalan periode sebelumnya.

```
> ema2=EMA(train, n = 2) #n adalah periode
> dataema2 = data.frame(ema2)
```

Gambar 4. 9 *Syntax* Metode EMA 2 Periode Jumlah Pendonor

Selanjutnya peneliti menggambarkan *plot* data aktual dan *plot* EMA dengan periode 2 dalam *plot* data aktual peneliti akan menggunakan warna biru dan untuk EMA menggunakan warna hitam baik pada data jumlah pendonor. Kemudian untuk menampilkannya, peneliti menggunakan fungsi `plot()`, `lines()`, dan `legend()`.

```
#plot menambahkan EMA(2)
plot(time(train), train, col = "blue", main = "Jumlah Pendonor", type = "b", pch = 21, cex = 0.5)
lines(time(ema2), ema2, col = "black", lwd = 2, type = "b", pch = 12, cex = 0.8)
legend("topleft", legend = c("TRAIN","EMA2"), col = c("blue","black"),
      pch = c(21,12), lty = 1,
      cex = 0.7, inset = 0.05)
```

Gambar 4. 10 *Syntax* Menggambar Plot EMA Jumlah Pendonor

4.4.1 Evaluasi Hasil Peramalan Exponential Moving Average

Kemudian peneliti akan menampilkan nilai *Mean Absolute Percentage Error (MAPE)* dari kedua data tersebut pada masing-masing periode baik pada data *training* maupun data *testing* jumlah pendonor.

```
#MAPE
mape.ema2=mean(abs(train-ema2)/train, na.rm = TRUE)*100
mape.ema2
#MAPE
mape.ema21=mean(abs(test-ema21)/test, na.rm = TRUE)*100
mape.ema21
```

Gambar 4. 11 Evaluasi Hasil Peramalan dengan MAPE Jumlah Pendonor Data *Training* dan Data *Testing*

4.4.2 Melakukan Peramalan Periode Kedepan

Selanjutnya peneliti akan melakukan peramalan pada lima periode kedepan dengan menggunakan perintah `forecast()` pada `h=13` dikarenakan jumlah data *testing* yang berjumlah 8 data. Berikut *syntax* yang digunakan.

```
# Melakukan peramalan 5 periode ke depan
ema2=EMA(train, n = 2)
forecast_values <- forecast(ema2, h = 13)
# Menampilkan hasil peramalan
print(forecast_values)
```

Gambar 4. 12 *Syntax* Peramalan Lima Periode Kedepan

BAB V

HASIL DAN PEMBAHASAN


5.1 Analisis Deskriptif

Data sekunder yang berhasil dikumpulkan merupakan data historis jumlah pendonor darah dari tanggal 1 Oktober 2023 hingga 31 Desember 2023. Data selanjutnya diolah dengan menggunakan bantuan *software Microsoft Excel* untuk melihat statistik deskriptif dari data. Berikut ini adalah analisis deskriptif dari data historis jumlah pendonor darah:

Tabel 5. 1 Analisis Deskriptif

Perhitungan	Pendonor
Nilai Minimum	10
<i>1st Qu.</i>	28
<i>Median</i>	51
<i>Mean</i>	56.73333
<i>3rd Qu.</i>	79
Nilai Maksimum	258
Standar Deviasi	39.77482

Berdasarkan tabel 5.1, terlihat bahwa analisis deskriptif yang terdapat dalam data historis jumlah pendonor darah dari tanggal 1 Oktober 2023 hingga 31 Desember 2023 yaitu nilai minimum, *1st quartil*, *median*, *mean*, *3rd. Quartil*, nilai maksimum, dan standar deviasi. Pada data jumlah pendonor darah didapatkan nilai minimum sebesar 10, nilai *1st quartil* sebesar 28, nilai *median* sebesar 51, nilai *mean* sebesar 56.7, nilai *3rd. Quartil* sebesar 79, nilai maksimum sebesar 258, dan nilai standar deviasi sebesar 39.77. Data historis jumlah pendonor darah tersebut dapat divisualisasikan seperti gambar di bawah ini:



Gambar 5.1 *Plot Data Aktual*

Berdasarkan grafik pada Gambar 5.1, dapat diketahui bahwa data historis jumlah pendonor darah dari tanggal 1 Oktober 2023 hingga 31 Desember 2023 memiliki pola musiman karena pola runtun waktu menunjukkan lembah yang berulang pada interval yang sama.

5.2 Stasioneritas

Selanjutnya peneliti akan melakukan uji stasioneritas pada data aktual yang telah disajikan. Uji stasioneritas dilakukan dengan beberapa uji akar unit (*unit root*) yang tersedia, contohnya Uji ADF (*Test Dickey-Fuller*), KPSS, atau *Phillips-Perron*. Apabila ditemui data tidak stasioner, maka harus dilakukan *differencing* terlebih dahulu. Uji stasioneritas dapat dilihat dari plot data aktual pada analisis deksriptif sebelumnya dan pada plot tersebut diperoleh bahwa data tidak stasioner. Peneliti akan melakukan uji ADF menggunakan *software RStudio* dengan hasil sebagai berikut.

```
> adf.test(train)

Augmented Dickey-Fuller Test

data: train
Dickey-Fuller = -3.6618, Lag order = 4, p-value = 0.03486
alternative hypothesis: stationary
```


Gambar 5.2 Hasil Uji Stasioneritas

Tabel 5.2 Hasil Uji Stasioneritas		
Variabel	<i>P-value</i>	Keputusan Akhir
Pendonor	0,03	Tolak H_0

Berdasarkan hasil uji ADF (*Test Dickey-Fuller*), diperoleh nilai *p - value* jumlah pendonor darah lebih kecil dari pada $\alpha = 0,05$, yang berarti tolak H_0 . Demikian berarti data tidak mengandung unit *root* (stasioner).

5.3 Analisis Pemodelan ARIMA

Peneliti akan melakukan analisis model ARIMA (*Autoregressive Integrated Moving Average*) setelah asumsi data stasioner terpenuhi. Peneliti akan menampilkan identifikasi model dengan jendela grafik baris 1 dan kolom 2 dalam bentuk *plot Autocorrelation Function (ACF)* dan *Partial Autocorrelation Function (PACF)* pada data Pendonor seperti gambar berikut ini.



Gambar 5.3 *Plot ACF dan PACF*

Berdasarkan *plot* diatas, batang ACF keluar hingga *lag* ke-17 yang menunjukkan *order MA* yaitu $q = 17$. Sementara batang PACF tidak ada *lag* yang keluar, sehingga tidak terdapat *lag* yang signifikan, dan menunjukkan *order AR* yaitu $p = 0$. Dengan sebelumnya tidak dilakukan *differencing order 1*, sehingga $d = 0$ dan diperoleh model

pertama ARIMA (0,0,17). Pendugaan terhadap model dapat dipilih model dengan *order* lebih rendah atau kombinasi dari *order* model utama, sehingga peneliti menambahkan orde (0,0,16), (0,0,15), (0,0,14), (0,0,13).

```

> model1 = Arima(train, order = c(0,0,17))
> summary(model1)
Series: train
ARIMA(0,0,17) with non-zero mean

Coefficients:
    ma1    ma2    ma3    ma4    ma5    ma6    ma7    ma8    ma9    ma10   ma11   ma12   ma13   ma14   ma15   ma16
s.e.  0.0867  0.0005  0.1542  -0.3127  0.0710  0.1809  0.1942  -0.0921  -0.1945  -0.1121  -0.1505  0.2180  0.2235  0.3940  -0.0635  0.2093
    ma17   mean
s.e.  0.4606  54.2132
    s.e.  0.1503  7.5511

sigma^2 = 1211; Log Likelihood = -330.31
AIC=698.61  AICc=714.78  BIC=740.5

Training set error measures:
      ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set 0.5403652 29.76073 21.33526 -39.99882 61.98903 0.5445193 0.01036251

```

Gambar 5. 4 Summary Model 1 ARIMA

Kemudian untuk melihat model terbaik, peneliti akan berfokus pada nilai *Akaike Information Criterion* (AIC), *Bayesian Information Criterion* (BIC) dan nilai *Mean Absolute Percentage Error* (MAPE) terkecil pada setiap model. Pada model 1, nilai AIC yaitu sebesar 698.61, nilai BIC yaitu sebesar 740.5, dan nilai MAPE sebesar 61.98903. Kemudian peneliti bisa melihat dari nilai *p-value* yang didapatkan dengan perintah `printstatarima()`, yang mana perintah tersebut didapatkan dari *function* yang sebelumnya telah dibuat, didapatkan *output* seperti gambar berikut ini.

```

> printstatarima(model1)

Coefficients:
           s.e.      t      sign.
ma1      0.0867  0.1555  0.5576  0.5790
ma2      0.0005  0.1707  0.0029  0.9977
ma3      0.1542  0.1572  0.9809  0.3302
ma4     -0.3127  0.1611 -1.9410  0.0565
ma5      0.0710  0.1686  0.4211  0.6750
ma6      0.1809  0.1472  1.2289  0.2235
ma7      0.1942  0.1420  1.3676  0.1761
ma8     -0.0921  0.1471 -0.6261  0.5334
ma9     -0.1945  0.1463 -1.3295  0.1883
ma10    -0.1121  0.1540 -0.7279  0.4692
ma11    -0.1505  0.1592 -0.9454  0.3479
ma12     0.2180  0.1664  1.3101  0.1947
ma13     0.2235  0.1757  1.2721  0.2078
ma14     0.3940  0.1643  2.3981  0.0193
ma15    -0.0635  0.1272 -0.4992  0.6193
ma16     0.2093  0.1584  1.3213  0.1910
ma17     0.4606  0.1503  3.0645  0.0032
intercept 54.2132  7.5511  7.1795  0.0000

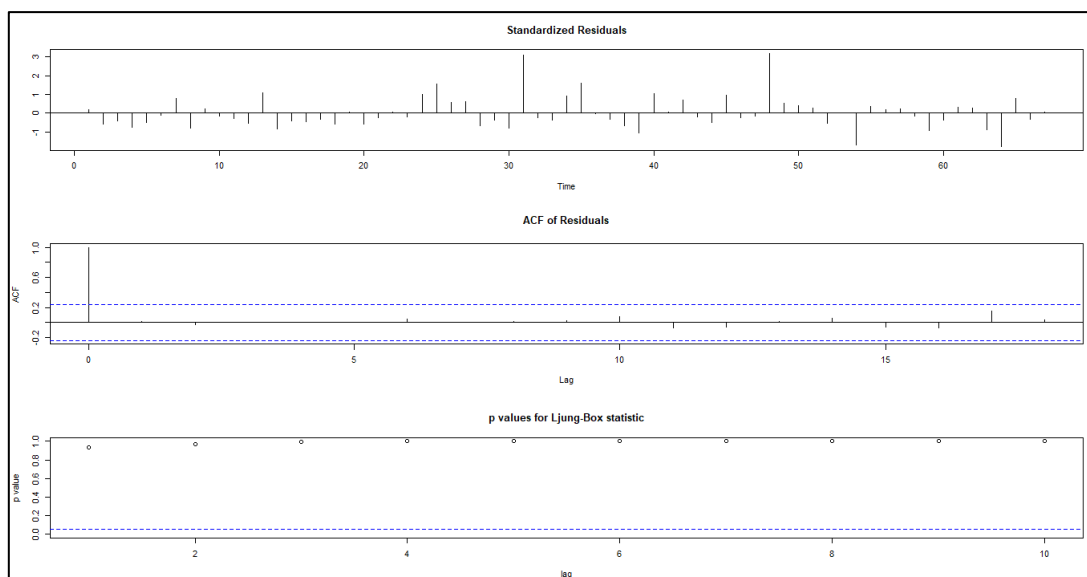
```

Gambar 5.5 Melihat Signifikansi dari Koefisien Model 1

Pada gambar diatas dapat kita lihat bahwa koefisien ma17 signifikan karena nilai *p-value* = 0.0032 kurang dari 0.05 yang artinya model 1 pada data jumlah pendonor darah signifikan.

Jika dibandingkan antara model 1 dengan model lainnya, melihat signifikansi dari koefisien model dan nilai AIC, BIC, serta MAPE terkecil terdapat pada model 1 yang artinya disini untuk model terbaik adalah model 1 pada data jumlah pendonor. Selanjutnya peneliti akan melakukan peramalan terhadap model 1 pada data *testing* dan *training*.

Sebelum itu peneliti akan melakukan uji diagnostik dengan menggunakan perintah `tsdiag()` pada model terbaik yaitu model 1, didapatkanlah *output* sebagai berikut.



Gambar 5. 6 Plot Uji *Diagnostic*

Dari gambar diatas terdapat *plot standardized residuals* dan *p-values for Ljung-Box statistic*. Berdasarkan uji residual, *lag Autocorrelation Function ACF* residual berada di dalam limit data jumlah pendonor darah. Nilai $p - value > \alpha$, yang menunjukkan tidak ada korelasi serial pada residual.

Setelah itu peneliti akan melakukan peramalan pada data testing periode terhadap model terbaik yang telah didapatkan yaitu model 1, berikut *output* yang didapatkan.

```

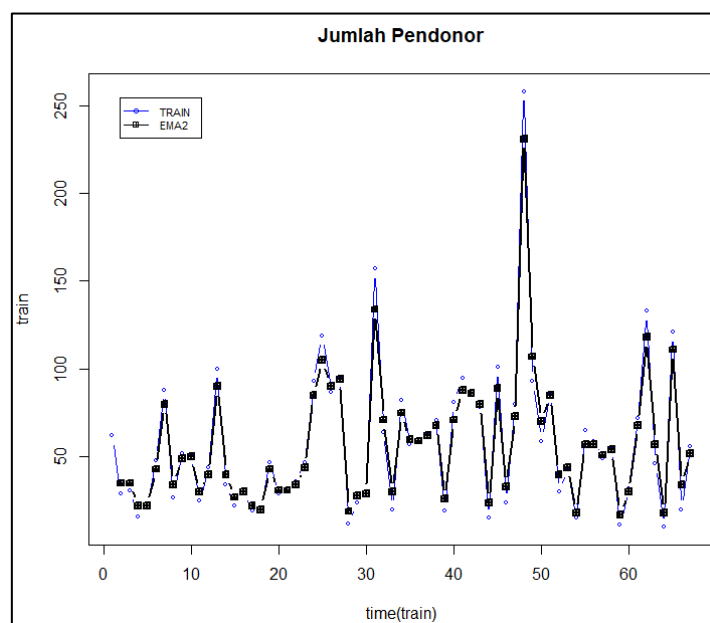
> model1 = Arima(train, order = c(0,0,17))
> pred.donor = forecast(model1, h = length(test))
> pred.donor=round(pred.donor$mean)
> pred.donor
Time Series:
Start = 68
End = 75
Frequency = 1
[1] 67 46 38 18 63 56 63 55

```

Gambar 5. 7 Prediksi Data *Testing* Data Jumlah Pendoror Darah

5.4 Exponential Moving Average (EMA)

Pemberian bobot pada *Exponential Moving Average* (EMA) melibatkan periode. Dengan kata lain, nilai peramalan untuk periode kedepan, sama dengan nilai peramalan periode sebelumnya. Dengan nilai awal EMA diambil dari nilai *Moving Average* (MA) sederhana. Nilai k merupakan panjang periode EMA.



Gambar 5. 8 Plot EMA(2) Jumlah Pendoror Darah

Berdasarkan plot yang ada, dapat dilihat *line* hitam mengikuti *line* data aktual, sehingga peneliti memiliki dugaan sementara bahwa nilai hasil peramalan tidak jauh berbeda dari data aktual yang dilihat berdasarkan plot data EMA pada data jumlah pendonor Darah.

	train	ema2
1	62	NA
2	29	35
3	31	35
4	16	22
5	22	22
6	48	43
7	88	80
8	27	34
9	52	49
10	51	50

Showing 1 to 11 of 67 entries, 2 total columns

Gambar 5. 9 Data teratas Hasil Peramalan EMA Jumlah Pendonor Darah *Training*

Rata-rata yang didapatkan dari EMA periode dua pada data jumlah pendonor darah adalah sebesar 35. Berdasarkan hasil rata-rata pada kedua data tersebut dapat disimpulkan bahwa hasil peramalan menggunakan *moving average* mendekati nilai pada data aktual.

Selanjutnya peneliti akan membandingkan nilai peramalan data *testing* pada data jumlah pendonor dengan hasil peramalan sebagai berikut.

```
> ema21= c(ema21$x)
> ema21
[1] NA 66 28 85 50 22 53 54
```

Gambar 5. 10 Data Hasil Peramalan EMA Jumlah Pendonor Darah Data *Testing*

Tabel 5. 3 Perbandingan Hasil Peramalan vs Data *Testing*

Pendonor	Forecasting
60	NA
70	66
24	28
95	85
44	50
16	22
58	53
56	54

Berdasarkan perbandingan dari data *testing* dan data aktual pada Tabel 5.3 diatas, dapat dilihat bahwa hasil peramalan data *testing* tidak jauh berbeda dari data aktual.

5.5 Evaluasi Model

Setelah dilakukan analisis peramalan data hitoris jumlah pendonor darah dari tanggal 1 Oktober 2023 hingga 31 Desember 2023 dengan metode ARIMA, peneliti akan mengukur tingkat kesalahan hasil peramalan. Pengukuran tingkat kesalahan tersebut dilihat berdasarkan nilai MAPE. MAPE merupakan pengukuran kesalahan yang menghitung ukuran persentase penyimpangan antara data aktual dengan data hasil peramalan. Berikut adalah hasil MAPE pada peramalan jumlah pendonor:

Tabel 5. 4 Perbandingan Metode Peramalan

ARIMA		<i>Exponential Moving Average</i>	
MAPE	Pendonor	MAPE	Pendonor
<i>Training</i>	61.99%	<i>Training</i>	15.36%
<i>Testing</i>	61.12%	<i>Testing</i>	13.75%

Berdasarkan hasil perhitungan *Mean Absolute Percentage Error* (MAPE) diatas, semakin kecil jumlah kesalahan (MAPE), maka metode yang digunakan semakin baik untuk digunakan sebagai peramalan.

Pada penelitian ini, jika menggunakan metode ARIMA didapatkan nilai MAPE pada data jumlah pendonor yaitu sebesar 61,99% untuk *training* dan 61,12% untuk *testing*. Selanjutnya jika menggunakan metode *Moving Average* khususnya *Exponential Moving Average* didapatkan nilai MAPE pada data jumlah pendonor darah yaitu sebesar 15,36% untuk *training* dan 13,75% untuk *testing*, sehingga dapat disimpulkan bahwa metode yang paling baik untuk dilakukan peramalan pada beberapa periode kedepan adalah metode *Moving Average* khususnya *Exponential Moving Average* karena memiliki nilai MAPE yang lebih kecil di bandingkan metode ARIMA.

5.6 Hasil Peramalan Periode Kedepan

Setelah dilakukan analisis peramalan data hitoris jumlah pendonor dari tanggal 1 Oktober 2023 hingga 31 Desember 2023 dengan metode metode *Moving Average* khususnya *Exponential Moving Average*, disini peneliti akan menampilkan hasil lima peramalan kedepan karena *Moving Average* memiliki nilai peramalan yang terbatas,

sehingga pada peramalan berikutnya akan menghasilkan nilai yang sama atau konstan. Berikut hasil peramalan pada lima periode kedepan yang didapatkan.

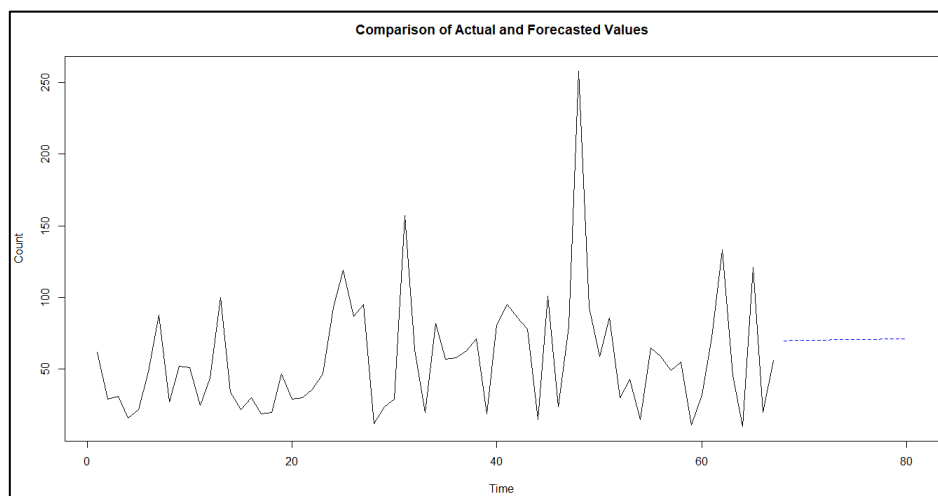
76	70.78550
77	70.87728
78	70.96589
79	71.05143
80	71.13401

Gambar 5. 11 Hasil Peramalan Lima Periode Kedepan

Tabel 5. 5 Hasil Peramalan Lima Periode Kedepan

Tanggal	Hasil Peramalan Pendoron
01/01/2024	70.7855 \approx 71
02/01/2024	70.8773 \approx 71
03/01/2024	70.9659 \approx 71
04/01/2024	71.0514 \approx 71
05/01/2024	71.1340 \approx 71

Jika dibuat visualisasinya, berikut plot *data aktual*, dan hasil peramalan lima periode kedepan berdasarkan hasil pada tabel 5.5.



Gambar 5. 12 Grafik Data Aktual dan Peramalan Lima Periode Kedepan Jumlah Pendoron Darah

Berdasarkan Gambar 5.12 di atas, hasil peramalan data historis jumlah pendonor darah memiliki pola *plot* yang konstan, tetapi berdasarkan visualisasi tersebut, peneliti dapat menyimpulkan bahwa hasil peramalan lima periode kedepan pada data cenderung memiliki nilai yang konstan dari tanggal 1 Januari 2024 hingga 5 Januari 2024 dengan

metode *Exponential Moving Average (EMA)*. Hal ini terbukti pada nilai peramalan lima periode kedepan yang terdapat pada Tabel 5.5 memiliki nilai pembulatan yang sama.

5.7 Implikasi Manajerial

Selanjutnya peneliti akan memberikan sebuah insight berupa implikasi manajerial terhadap hasil peramalan lima periode kedepan sejak tanggal 1 Januari 2024 hingga 5 Januari 2024 pada data jumlah pendonor darah. Berikut merupakan beberapa implikasi manajerial yang didapatkan berdasarkan hasil peramalan lima periode kedepan:

1. Perencanaan Persediaan Darah

Dengan menggunakan hasil peramalan tersebut, PMI Kabupaten Sleman dapat memperkirakan kebutuhan darah di masa depan. Hal ini memungkinkan mereka untuk mengelola persediaan dengan lebih efisien, menghindari kekurangan atau kelebihan stok darah. Manajemen persediaan yang baik dapat membantu memastikan ketersediaan darah yang cukup untuk memenuhi permintaan, terutama selama periode musiman atau saat terjadi kejadian darurat.

2. Promosi dan Pemasaran

Peramalan bisa membantu PMI dalam merencanakan kegiatan promosi dan pemasaran. Misalnya, jika peramalan menunjukkan pola yang konstan bahkan terjadinya penurunan jumlah pendonor darah pada suatu periode tertentu, PMI dapat merespons dengan mengadakan kampanye pemasaran yang lebih agresif atau mengorganisir acara promosi untuk meningkatkan partisipasi masyarakat.

3. Optimasi Sumber Daya

Dengan memahami pola peramalan, PMI dapat mengatur jadwal dan alokasi sumber daya dengan lebih efisien. Hal ini bisa berupa penjadwalan staf, pengaturan lokasi donor darah, dan penentuan waktu untuk mengadakan acara donor darah. Dengan menggunakan peramalan untuk memprediksi waktu-waktu dengan tingkat partisipasi yang tinggi, PMI dapat mengoptimalkan penggunaan sumber daya mereka.

4. Pengembangan Program Kesadaran dan Pendidikan Masyarakat

Peramalan menunjukkan hasil yang konstan dalam jumlah pendonor darah, PMI dapat menggunakan hasil peramalan ini sebagai dasar untuk mengembangkan

program-program kesadaran dan pendidikan masyarakat. Hal ini bisa meliputi kampanye edukasi tentang pentingnya donor darah, program insentif untuk mendorong partisipasi, atau kemitraan dengan organisasi lokal untuk mengadakan acara promosi.

Berdasarkan implikasi manajerial diatas, PMI Kabupaten Sleman dapat meningkatkan efisiensi operasional mereka, memaksimalkan dampak sosial positif, dan memastikan ketersediaan darah yang memadai untuk keperluan medis darurat dan rutin.

BAB VI PENUTUP

6.1 Kesimpulan

Berdasarkan hasil analisis dan pengolahan data pada penelitian ini, mendapatkan kesimpulan untuk menjawab rumusan masalah:

1. Dalam penelitian ini model prediksi jumlah pendonor darah yang berbasis machine learning di PMI Kabupaten Sleman adalah dengan menggunakan komposisi data training 90% dan data testing 10%. Mendapatkan Tingkat error MAPE ARIMA pada data jumlah pendonor yaitu sebesar 61,99% untuk *training* dan 61,12% untuk *testing*, sedangkan MAPE EMA pada data jumlah pendonor darah yaitu sebesar 15,36% untuk *training* dan 13,75% untuk *testing*, sehingga dapat disimpulkan bahwa metode yang paling baik untuk dilakukan peramalan pada beberapa periode kedepan adalah metode *Exponential Moving Average* (EMA) karena memiliki nilai MAPE yang lebih kecil di bandingkan metode ARIMA.
2. Didapatkan model prediksi jumlah pendonor darah yang berbasis *machine learning* dengan menggunakan metode *Exponential Moving Average* (EMA) yang hasilnya sebesar 70, 70, 70, 71, 71 untuk lima periode kedepan.

6.2 Saran

Berdasarkan dari hasil penelitian yang dilakukan, dapat disarankan sebagai berikut.

1. Pada penelitian selanjutnya, pemodelan dengan ARIMA dan EMA dapat melakukan identifikasi terhadap tenaga medis dan alat-alat tenaga medis yang dibutuhkan dalam kegiatan donor darah, serta dapat mencari sumber acuan yang lebih banyak dalam mengidentifikasi model ARIMA dan EMA agar dapat memperoleh model yang lebih baik.

DAFTAR PUSTAKA

- Andyani, K. D. W., & Juniarta, M. G. (2020). Efektivitas Latihan Yoga dalam Mengatasi Penyakit Jantung Koroner (PJK). *JURNAL YOGA DAN KESEHATAN*, 3(2), 129–141. <http://ejournal.ihdn.ac.id/index.php/jyk>
- ArunKumar, K. E., Kalaga, D. V., Kumar, Ch. M. S., Kawaji, M., & Brenza, T. M. (2022). Comparative Analysis of Gated Recurrent Units (GRU), Long Short-Term Memory (LSTM) Cells, Autoregressive Integrated Moving Average (ARIMA), Seasonal Autoregressive Integrated Moving Average (SARIMA) for Forecasting COVID-19 Trends. *Alexandria Engineering Journal*, 61(10), 7585–7603. <https://doi.org/10.1016/j.aej.2022.01.011>
- Brillinger, D. R. (2005). Time Series: General. In *International Encyclopedia of the Social & Behavioral Sciences*. Elsevier.
- Chyon, F. A., Suman, Md. N. H., Fahim, Md. R. I., & Ahmmed, Md. S. (2022). Time Series Analysis and Predicting COVID-19 Affected Patients by ARIMA Model using Machine Learning. *Journal of Virological Methods*, 301, 1–6. <https://doi.org/10.1016/j.jviromet.2021.114433>
- Dave, E., Leonardo, A., Jeanice, M., & Hanafiah, N. (2021). Forecasting Indonesia Exports using a Hybrid Model ARIMA-LSTM. *Procedia Computer Science* 179, 179, 480–487. <https://doi.org/10.1016/j.procs.2021.01.031>
- Fahmi, K., Santosa, S., & Fanani, A. Z. (2015). Optimasi Parameter Artificial Neural Netowrk dengan Menggunakan Algoritma Genetik untuk Memprediksi Nilai Tukar Rupiah. *Jurnal Teknologi Informasi*, 11(2), 197–209. <http://research.pps.dinus.ac.id>
- Fathurohman, A. (2021). Machine Learning untuk Pendidikan: Mengapa dan Bagaimana. *Jurnal Informatika Dan Teknologi Komputer (JITEK)*, 1(3), 57–62.
- Fauzani, S. P., & Rahmi, D. (2023). Penerapan Metode ARIMA Dalam Peramalan Harga Produksi Karet di Provinsi Riau. *Jurnal Teknologi Dan Manajemen Industri Terapan (JTMIT)*, 2(4), 269–277.
- Gupta, A., & Kumar, A. (2022). Two-step daily reservoir inflow prediction using ARIMA-machine learning and ensemble models. *Journal of Hydro-Environment Research*, 45, 39–52. <https://doi.org/10.1016/j.jher.2022.10.002>

- Hanke, J. E., & Wichern, D. W. (2005). *Business Forecasting*. Prentice Hall.
- Hardini, I. R. (n.d.). A Survey on Machine learning and IoT. *ITEJ Desember-2019*, 4(2).
- Heizer, J., & Render, B. (2009). *Manajemen Operasi* (9th ed., Vol. 1). Salemba Empat.
- Ji, L., Zou, Y., He, K., & Zhu, B. (2019). Carbon Futures Price Forecasting based with ARIMA-CNN-LSTM model. *Procedia Computer Science* 162, 162, 33–38. <https://doi.org/10.1016/j.procs.2019.11.254>
- Kementrian Kesehatan RI. (2014). *Peraturan Kementrian Kesehatan Republik Indonesia Nomor 83*.
- Kobiela, D., Krefta, D., Król, W., & Weichbroth, P. (2022). ARIMA vs LSTM on NASDAQ Stock Exchange Data. *Procedia Computer Science* 207, 207, 3830–3839. <https://doi.org/10.1016/j.procs.2022.09.445>
- Kolker, A. (2011). *Healthcare Management Engineering: What Does This Fancy Term Really Mean? The Use of Operations Management Methodology for Quantitative Decision-Making in Healthcare Settings*. Springer.
- Krishnamoorthy, U., Karthika, V., Mathumitha, M. K., Panchal, H., Jatti, V. K. S., & Kumar, A. (2024). Learned Prediction of Cholesterol and Glucose using ARIMA and LSTM Models – A Comparison. *Results in Control and Optimization*, 14, 1–15. <https://doi.org/10.1016/j.rico.2023.100362>
- Li, Y., Wu, K., & Liu, J. (2023). Self-Paced ARIMA for Robust Time Series Prediction. *Knowledge-Based Systems*, 269.
- Luo, J., & Gong, Y. (2023). Air Pollutant Prediction Based on ARIMA-WOA-LSTM Model. *Atmospheric Pollution Research*, 14(6), 1–13. <https://doi.org/10.1016/j.apr.2023.101761>
- Mahadewa, A., Aryawan, M. G., & Prasetyo Utomo, P. E. (2018). Peramalan Indeks Harga Prulink Rupiah Equity Fund Dengan Metode Exponential Moving Average. *Jurnal Sistem Informasi Dan Komputer Terapan Indonesia (JSIKTI)*, 1(2), 87–96. <https://doi.org/10.33173/jsikti.18>
- Marvillia, B. L. (2013). Pemodelan dan Peramalan Penutupan Harga Saham PT Telkom dengan Metode ARCH-GARCH. *MATHunesa: Jurnal Ilmiah Matematika*, 1(1), 1–8.
- Mati, S., Radulescu, M., Saqib, N., Samour, A., Ismael, G. Y., & Aliyu, N. (2023). Incorporating Russo-Ukrainian War in Brent Crude Oil Price Forecasting: A Comparative Analysis of ARIMA, TARMA and ENNReg Models. *Heliyon*, 9(11), 1–15. <https://doi.org/10.1016/j.heliyon.2023.e21439>

- Mulyanto. (2009). *Sistem Informasi Konsep dan Aplikasi*. Pustaka Pelajar Yogyakarta.
- Ray, S., Lama, A., Mishra, P., Biswas, T., Das, S. S., & Gurung, B. (2023). An ARIMA-LSTM Model for Predicting Volatile Agricultural Price Series with Random Forest Technique. *Applied Soft Computing*, 149(A).
- Rozi Lubis, F., Khoiruddin Harahap, M., & Mahmud Husein, A. (2019). *Analisis Prediktif untuk Keputusan Bisnis : Peramalan Penjualan*. <https://doi.org/10.3390/xxxxx>
- Shwartz, S. S., & David, S. Ben. (2004). *Understanding Machine Learning*. Cambridge University Press.
- Utami, R., Dwi Pratama, K., Atmojo, S., Teknologi Adhi Tama Surabaya, I., Arief Rachman Hakim No, J., Wijaya Putra, U., & Benowo No, J. (2022). *Comparison of Exponential Moving Average and Brown's Double Exponential Smoothing Method for Forecasting Glass Craft Sales Perbandingan Metode Exponential Moving Average dan Brown's Double Exponential Smoothing untuk Peramalan Penjualan Kerajinan Kaca* (Vol. 2, Issue 2).
- Williams, B. K., & Sawyer, S. C. (2007). *Using Information Technology: A Practical Introduction to Computers & Communication* (7th Edition). McGraw-Hill.
- Zahara, S., & Sugianto. (2021). Peramalan Data Indeks Harga Konsumen Berbasis Time Series Multivariate Menggunakan Deep Learning. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1), 24–30. <https://doi.org/10.29207/resti.v5i1.2562>

LAMPIRAN

Lampiran 1. Data Jumlah Pendonor Darah PMI Kabupaten Sleman Setelah Dilakukan
Pre-Processing Data.

Tanggal	Jumlah_Pendonor
01/10/2023	62
03/10/2023	29
04/10/2023	31
05/10/2023	16
06/10/2023	22
07/10/2023	48
08/10/2023	88
10/10/2023	27
11/10/2023	52
12/10/2023	51
13/10/2023	25
14/10/2023	44
15/10/2023	100
17/10/2023	34
18/10/2023	22
19/10/2023	30
20/10/2023	19
21/10/2023	20
22/10/2023	47
23/10/2023	29
24/10/2023	30
25/10/2023	36
26/10/2023	47
27/10/2023	93
28/10/2023	119
29/10/2023	87
30/10/2023	95
31/10/2023	12
02/11/2023	24
03/11/2023	29
04/11/2023	157
05/11/2023	64
08/11/2023	20

Tanggal	Jumlah_Pendonor
09/11/2023	82
10/11/2023	57
11/11/2023	58
12/11/2023	63
14/11/2023	71
15/11/2023	19
16/11/2023	81
17/11/2023	95
18/11/2023	86
19/11/2023	78
20/11/2023	15
21/11/2023	101
22/11/2023	24
24/11/2023	80
25/11/2023	258
26/11/2023	93
28/11/2023	59
29/11/2023	86
30/11/2023	30
01/12/2023	43
02/12/2023	15
03/12/2023	65
04/12/2023	59
05/12/2023	49
06/12/2023	55
07/12/2023	11
08/12/2023	32
09/12/2023	72
10/12/2023	133
12/12/2023	46
13/12/2023	10
14/12/2023	121
15/12/2023	20
16/12/2023	56
17/12/2023	60
20/12/2023	70
21/12/2023	24
23/12/2023	95

Tanggal	Jumlah_Pendonor
24/12/2023	44
29/12/2023	16
30/12/2023	58
31/12/2023	56

Lampiran 2. Surat Ijin Penelitian



FAKULTAS
TEKNOLOGI INDUSTRI

Gedung KH. Mas Mansur
Kampus Terpadu Universitas Islam Indonesia
Jl. Kaliurang km 14,5 Yogyakarta 55584
T. (0274) 898444 ext. 4110, 4100
F. (0274) 895007
E. fti@uii.ac.id
W. fti.uii.ac.id

Nomor : 1/penelitian TA/Sek.Prodi.S1/20/TI/I/2023
Lampiran : -
Hal : Permohonan ijin penelitian tugas akhir

Kepada Yth.
Bapak/Ibu Pimpinan
Palang Merah Indonesia, Kabupaten Sleman
Jl. Dr. Radjimin, Sucen, Triharjo, Kec. Sleman, Kabupaten Sleman, Daerah Istimewa
Yogyakarta 55514
Sleman, Yogyakarta

Assalamu'alaikum wr. wb

Berkaitan dengan kegiatan penelitian mahasiswa Prodi Teknik Industri Fakultas Teknologi Industri Universitas Islam Indonesia yaitu

No	Nama Mahasiswa	NIM	Penelitian
1.	Muhammad Tri Rahffi	19522350	Implementasi Machine Learning Dalam Memprediksi Jumlah Kebutuhan Tenaga Medis Dengan Menggunakan Model ARIMA (Studi Kasus : PMI Sleman)

Maka bersama ini kami memohon kepada Bapak/Ibu untuk memberikan ijin kepada Mahasiswa tersebut untuk melakukan penelitian di instansi yang Bapak/Ibu pimpin.

Demikianlah surat permohonan ini kami sampaikan, atas perhatian dan kerjasamanya kami ucapkan terima kasih.

Wassalamu'alaikum wr. wb.

Yogyakarta, 27 Jumadil Akhir 1445 H H
9 Januari 2024 M

Sek. Prodi S1 Teknik Industri

Amalia Dila Sari, S.T., M.Sc.
