

## Analisis Deret Waktu Data Perencanaan Tenaga Kerja pada Perusahaan Manufaktur Menggunakan Model ARIMA

### Time Series Analysis of Man Power Planning Data at Manufacturing Company Using ARIMA Model

Asep Yusapra Salim<sup>1</sup>, Mila Yuliani<sup>2</sup>, Mutiara Andayani Komara<sup>3</sup>, Rani Sri Wahyuni<sup>4</sup>

<sup>1</sup>Universitas Kartamulia, <sup>2</sup>Politeknik Kepribadian, <sup>3,4</sup>Sekolah Tinggi Teknologi Wastukencana

<sup>1</sup>asepyusaprasalim@univkartamulia.ac.id, <sup>2</sup>milayuliani.skom@gmail.com,

<sup>3</sup>mutiara@wastukencana.ac.id, <sup>4</sup>rani@wastukencana.ac.id

Corresponding author: asepyusaprasalim@univkartamulia.ac.id

---

**Abstrak.** Dalam dunia industri, peramalan merupakan bagian yang sangat penting untuk dijadikan dasar perencanaan strategis, pertumbuhan bisnis, proyeksi pendapatan, dan pengambilan keputusan suatu organisasi atau perusahaan. Perencanaan tenaga kerja atau workforce planning, memang krusial bagi organisasi dari semua ukuran. Hal ini melibatkan analisis dan peramalan secara strategis terhadap kebutuhan tenaga kerja organisasi saat ini dan masa depan untuk memastikan bahwa organisasi memiliki jumlah karyawan yang tepat dengan keterampilan yang sesuai pada peran yang tepat pada waktu yang tepat. Salah satu analisis yang dapat digunakan untuk peramalan adalah analisis data dengan menggunakan Metode Time Series. Salah satu aspek yang dapat dianalisis adalah Man Power Planning pada Perusahaan Manufaktur. Dengan mengetahui peramalan, perencanaan tenaga kerja dapat diukur dari segi produktivitas, efisiensi, dan keberlanjutan operasional organisasi atau perusahaan. Data ini telah dianalisis menggunakan Model ARIMA, yang dapat menghasilkan data perbandingan sebagai referensi data untuk mendukung keputusan lebih lanjut bagi Perusahaan Manufaktur. Hasil analisis ini memberikan panduan yang berharga bagi manajemen perusahaan dalam mengambil keputusan terkait perencanaan sumber daya manusia, meliputi: mengoptimalkan produktivitas, mengurangi biaya operasional, dan meningkatkan efisiensi operasional perusahaan secara keseluruhan. Tujuan utama penelitian ini adalah untuk memodelkan dan meramalkan kebutuhan tenaga kerja pada sebuah perusahaan manufaktur menggunakan metode Time Series, khususnya model ARIMA.

**Kata kunci:** Model ARIMA, Peramalan, Perencanaan Tenaga Kerja, Rencana Target, Analisis Deret Waktu.

**Abstract.** In the industrial world, forecasting is a very important part to be used as a basis for strategic planning, business growth, revenue projections, and decision-making of an organization or company. Manpower planning or workforce planning, is indeed crucial for organizations of all sizes. It involves strategically analyzing and forecasting an organization's current and future workforce needs to ensure that it has the right number of employees with the appropriate skills in the right roles at the right time. One of the analyses that can be used for forecasting is data analysis using the Time Series Method. One aspect that can be analyzed is Man Power Planning in the Manufacturing Company. By knowing the forecasting, workforce planning can be measured in terms of productivity, efficiency, and sustainability of the organization's or company's operations. This data has been analyzed using the ARIMA Model, which can produce comparative data as a data reference to support further decisions for the Manufacturing Company. The results of this analysis provide valuable guidance for company management in making decisions related to human resource planning, including: optimizing productivity, reducing operational costs, and increasing the efficiency of the company's overall operations. This research aims to use the ARIMA model to forecast the workforce requirements of a manufacturing company, based on Time Series analysis.

**Keywords:** ARIMA Model, Forecasting, Man Power Planning, Target Plan, Time Series Analysis.

---

## 1 Pendahuluan

Peramalan dalam dunia industri merupakan hal yang krusial dalam pengambilan keputusan. Hal ini dikarenakan peramalan dapat memberikan beberapa rekomendasi mengenai referensi dalam bahan pendukung pengambilan keputusan bagi level manajerial. Rekomendasi dapat diterima

apabila tersedia peramalan yang lebih baik bagi para pemimpin. Prediksi yang dibuat seringkali didasarkan pada data masa lalu yang dianalisis dengan menggunakan metode tertentu.

Hal ini dikarenakan perusahaan berlomba-lomba untuk menjadi pemenang dengan cara meningkatkan layanannya dan berharap penjualan produknya dapat meningkat dengan berbagai cara, termasuk dengan menggunakan teori optimasi. Namun, minimnya analisis data menjadi permasalahan yang sering ditemui. (Nugroho et al., 2023). Beberapa tahapan penting dalam menganalisis data antara lain: mengumpulkan data masa lalu kemudian meneliti dan menganalisisnya pada kurun waktu tertentu. Karena faktor utamanya adalah waktu, maka hasil analisis ini dapat dianggap sebagai apa yang akan terjadi di masa mendatang. (Ariyanto & Tamam, 2020a). Salah satu bagian dari dunia industri yang harus dikelola dengan baik adalah bagian Manajemen Sumber Daya Manusia yang berfokus pada Perencanaan Tenaga Kerja atau Pegawai. Dua aspek utama yang menjadi perhatian adalah perencanaan penempatan dan pengaturan pegawai. Hal ini karena manajemen kepegawaian yang efektif dapat menjadi kunci keberhasilan suatu perusahaan. Perencanaan tenaga kerja yang baik memastikan jumlah dan jenis pekerjaan yang tepat tersedia pada waktu yang tepat, sehingga mengoptimalkan produktivitas dan efisiensi operasional. (Kabul & Febrianto, 2022).

Untuk mencapai tujuan ini, perusahaan harus menggunakan metode dan teknologi yang tepat yang dapat menunjukkan arah bagaimana hasil yang diperoleh dapat akurat. (Arifin et al., 2023). Salah satu analisis yang dapat mendukungnya adalah analisis dengan Metode Time Series dengan Model ARIMA yang dapat membantu dalam membuat perencanaan strategis, pertumbuhan bisnis, proyeksi pendapatan, dan pengambilan keputusan suatu organisasi atau perusahaan. Salah satunya adalah Target Rencana Tahunan. (Febriyanti & Rifai, 2022). Prediksi deret waktu merupakan isu penting dalam banyak bidang, dan pembelajaran mendalam telah muncul sebagai metode yang menjanjikan untuk meningkatkan akurasi prediksi. (Diqi et al., 2023). Peramalan Deret Waktu juga merupakan cara yang memungkinkan solusi peramalan berdasarkan data terkini atau periode pendek untuk meramalkan data masa mendatang. (Sidqi & Sumitra, 2019). Dengan menggunakan metode deret waktu, keakuratan ramalan bergantung pada karakteristik deret waktu permintaan. (Matsumoto & Ikeda, 2015). Deret waktu tidak lain hanyalah pengamatan kronologis. (Bozarth et al., 2008). Model peramalan deret waktu menggunakan teknik matematika berdasarkan data historis untuk meramalkan permintaan. Model ini didasarkan pada asumsi bahwa masa depan merupakan perpanjangan dari masa lalu; itulah sebabnya kita dapat menggunakan data historis untuk memprediksi permintaan di masa mendatang. (Wisner et al., 2014). Metode ini memberi perusahaan dasar yang jelas untuk mengelola rencana kepegawaian dan mengidentifikasi potensi kekurangan atau kelebihan di masa mendatang. (Buulolo et al., 2023).

Analisis estimasi Man Power Planning dengan menggunakan pendekatan analisis time series yang memanfaatkan data historis, dapat memberikan keuntungan berupa informasi mengenai kebutuhan tenaga kerja suatu organisasi yang lebih akurat dalam menilai kebutuhan personelnnya dan mengambil langkah strategis dalam pengelolaan personel. (Zaky et al., 2023). Penelitian ini menggunakan model ARIMA (Autoregressive Integrated Moving Average) yang biasa dikenal dengan model BOX-Jenkins, yaitu suatu teknik untuk menemukan model yang paling sesuai dari sekumpulan data (kurva tambahan). Prinsip Box – Jenkins mencakup tiga langkah iteratif yaitu definisi model, estimasi parameter, dan verifikasi diagnostik. (Wold, 1938). Aturan utama untuk identifikasi model adalah jika deret waktu diperoleh dari proses ARIMA, deret waktu tersebut harus memiliki sifat autokorelasi teoritis. Dengan menggabungkan model autokorelasi teoritis dan eksperimental, kami membantu mengidentifikasi satu atau lebih model potensial untuk deret waktu tertentu. Box dan Jenkins. (Box et al., 2015). Diusulkan untuk menggunakan fungsi autokorelasi (ACF) dan fungsi autokorelasi parsial (PACF) dari data sampel sebagai alat dasar untuk menentukan urutan model ARIMA. Model ARIMA adalah model yang sepenuhnya mengabaikan variabel independen untuk membuat prediksi. ARIMA menggunakan nilai masa lalu dan masa kini dari variabel dependen untuk membuat prakiraan jangka pendek yang akurat. ARIMA cocok jika pengamatan berasal dari deret waktu yang memiliki hubungan statistik satu sama lain (ketergantungan). (John & Latupeirissa, 2021). ARIMA yang menerapkan teknik korelasi. Identifikasi model dilakukan dengan memeriksa ACF (Autocorrelation Function) dan PACF (Partial Autocorrelation Function) dari suatu deret waktu. Tujuan dari model ARIMA dalam penelitian ini adalah untuk menemukan model yang akurat dalam merepresentasikan pola masa lalu dan masa depan dari data deret waktu yang dianalisis. (Ariyanto & Tamam, 2020b). Memilih model deret waktu yang sesuai dengan data akan menghasilkan akurasi prediktif. Menjalankan proses tersebut

akan menambahkan deret waktu baru yang mewakili nilai prediksi atau kecocokan model, sisanya (kesalahan kecocokan), dan interval keyakinan 95% dari kecocokan tersebut. (Kendall et al., 1971). Model terbaik adalah model yang sesederhana mungkin dan meminimalkan kriteria tertentu, yaitu AIC, SBC, varians, dan kemungkinan maksimum. (Brockwell & Davis, 2009). Model yang dipilih adalah model ARIMA (0, 1, 1). Untuk model lainnya, salah satu nilai kriteria minimisasi lebih besar daripada nilai yang ditemukan dalam model ARIMA (1, 0, 1) pada nilai konstan. (Hamilton, 1994) Setiap model memiliki karakteristiknya masing-masing, sehingga berdasarkan karakteristik tersebut pada penelitian ini digunakan model ARIMA sebagai acuan yang dianggap paling tepat terhadap data yang dianalisis. Model ARIMA dijalankan pada data differencing atau discriminant dengan membiarkan data tersebut stasioner atau konstan. Model ARIMA (p,d,q) merupakan gabungan dari model ARMA (p,q) dan proses differencing atau discriminant. Differencing atau Discrimination merupakan proses mereduksi data dari waktu ke waktu, dengan tujuan agar data differencing tersebut menjadi stasioner. (Maulana, 2018). Rumus berikut dijelaskan pada (1)

$$\Sigma Y_t = u_n + \alpha_1 y_t + \Sigma profit_t = \mu n + \beta_0 \Sigma z_t + \beta_1 \Sigma z_{t-1} \quad (1)$$

Kombinasi pendekatan time series, target plan, dan ARIMA dapat membantu perusahaan mengetahui peramalan dalam merencanakan kebutuhan tahunan salah satunya dalam hal tenaga kerja sehingga analisisnya dapat dilakukan dengan baik.

## 2 Kajian Pustaka

### 2.1 Analisis Deret Waktu

Analisis deret waktu adalah suatu metode statistik yang digunakan untuk menganalisis data yang dikumpulkan secara berurutan berdasarkan waktu. Data ini bisa berupa apapun, mulai dari harga saham, suhu udara, jumlah pengunjung website, hingga data penjualan produk. (Safitri et al., 2021). Analisis ini sangat penting guna mengidentifikasi pola, membuat prediksi, dan mengevaluasi kinerja. Komponen yang ada dalam deret waktu terdiri dari: Tren (*Trend*), Musiman (*Seasonality*), Siklus (*Cycle*), dan Noise (*Noice*).

### 2.2 Perencanaan

Perencanaan adalah suatu proses yang melibatkan pemikiran secara sistematis tentang tindakan yang akan dilakukan di masa depan. Ini mencakup kegiatan menetapkan tujuan, mengidentifikasi langkah-langkah yang diperlukan untuk mencapai tujuan tersebut, serta mempertimbangkan berbagai kemungkinan yang dapat terjadi. (Prasasti Dewi & Wirasuta, 2021). Tujuan utama dari perencanaan adalah mengantisipasi masa depan, mencapai tujuan, mengoptimalkan sumber daya, dan mengelola resiko. (Komara et al., 2023)

### 2.3 Tenaga Kerja

Tenaga Kerja atau Sumber Daya Manusia (SDM) merupakan aset vital bagi setiap organisasi. Kinerja dan kepuasan SDM secara langsung berdampak pada keberhasilan organisasi di masa depan. Oleh karena itu, pengelolaan SDM yang efektif sangat penting untuk menciptakan lingkungan kerja yang kondusif dan meningkatkan produktivitas. (Rizqi & Nabila, 2022)

### 2.4 Model ARIMA


Model ARIMA (Auto Regressive Integrated Moving Average) adalah sebuah model statistik yang digunakan untuk analisis deret waktu dan peramalan. Ini merupakan metode yang populer untuk memodelkan dan meramalkan data deret waktu yang menunjukkan pola musiman, tren, dan fluktuasi acak. Komponen-komponen Model ARIMA: Autoregressive (AR): Komponen ini mengasumsikan bahwa nilai saat ini dari deret bergantung pada nilai-nilai masa lalunya sendiri. Hal ini ditandai dengan orde (p) dari proses autoregressive.; Integrated (I): Komponen ini memperhitungkan non-stasioneritas dalam data. Jika data tidak stasioner (yaitu, rata-rata atau varians berubah seiring waktu), maka dilakukan differencing (dikurangi dari nilai sebelumnya)

untuk membuatnya stasioner. Orde differencing dilambangkan dengan (d).; dan Moving Average (MA): Komponen ini mengasumsikan bahwa nilai saat ini dari deret bergantung pada kesalahan residual dari periode waktu masa lalu. Hal ini ditandai dengan orde (q) dari proses moving average. (Utami et al., 2023).

### 3 Metode

#### 3.1 Alur Penelitian

Terdapat beberapa langkah atau tahapan dalam penyusunan penelitian ini. Dimulai dari pengumpulan data, praproses (analisis data, pemilihan atribut, transformasi data), pengujian data dengan RapidMiner, dan analisis hasil. Berikut ini adalah langkah-langkah yang dilakukan, ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

Berdasarkan data pada Gambar 1, berikut penjelasan lebih lanjut terkait tahapan Rencana Penelitian.

##### 3.1.1 Pengumpulan Data (Data Collection)

Data Collection atau Pengumpulan data sebagian besar terdiri dari perolehan data, pelabelan data, dan perbaikan data atau model yang ada. (Roh et al., 2021). Data sampel ditunjukkan pada Tabel 1.

Tabel 1. Sampel Data Penelitian

| Employee ID | First Name | Department           | Category Employee |
|-------------|------------|----------------------|-------------------|
| 12080001    | Carrissa   | Business Development | Hourly            |
| 12020003    | Niels      | Support              | Hourly            |
| 22120004    | Dinny      | Support              | All In            |

Tabel 1 menunjukkan contoh data yang berisi `employee_id`, `first_name`, `department`, dan `category_employee`.

##### 3.1.2 PraProses (Preprocessing)

Preprocessing atau Praproses adalah mengubah teks ke dalam bahasa yang lebih alami. Secara umum ada beberapa tahapan dalam text praproses, yaitu:

###### 3.1.2.1 Menganalisis Data (Analyzing Data)

Pada langkah ini dilakukan pembersihan data dari data yang tidak mempunyai pola umum (outliers), duplikasi data dan data hilang atau rusak, normalisasi, dan metode interpolasi. Proses *cleaning* data atau pembersihan data dilakukan secara manual menggunakan Excel atau aplikasi pengolah data lainnya. Hal ini berfungsi untuk melakukan pembersihan data sebelum digunakan atau diimpor ke dalam RapidMiner yang kemudian akan dianalisa lebih lanjut. Pada tabel 2 di bawah ini, merupakan sampel tabel MPP Forecasting Annually yang menjadi bahan acuan data yang diambil data nya per tahun. Data berikut ini sudah digabungkan berdasarkan tabel per departemen dan dihilangkan data-data yang bersifat duplikat.

Tabel 2. Sample Data MPP Forecasting Annually yang digunakan pada Analisis Data

| Dept.        | Agustus         |                |               |                 |                |                  |                       |                     | September       |                |               |                     |                    |                  |                       |                 |
|--------------|-----------------|----------------|---------------|-----------------|----------------|------------------|-----------------------|---------------------|-----------------|----------------|---------------|---------------------|--------------------|------------------|-----------------------|-----------------|
|              | Perfor<br>mance | Target<br>Plan | Head<br>Count | Recruit<br>ment | Retire<br>ment | Target<br>Actual | Forec<br>ast<br>Value | Forec<br>ast<br>Sum | Performa<br>nce | Target<br>Plan | Head<br>Count | Recru<br>itmen<br>t | Retir<br>emen<br>t | Target<br>Actual | Forec<br>ast<br>Value | Forecast<br>Sum |
| Plant A      | 13,33           | 1,5            | 1370          | 1110            | 0              | 3720             | 2350                  | Recruit<br>ment     | 13,33           | 1              | 2480          | 0                   | 0                  | 2480             | 0                     | -               |
| Plant B      | 10,50           | 1              | 1665          | 0               | 0              | 1665             | 0                     | -                   | 10,50           | 1              | 1665          | 0                   | 0                  | 1665             | 0                     | -               |
| .....        |                 |                |               |                 |                |                  |                       |                     |                 |                |               |                     |                    |                  |                       |                 |
| <b>TOTAL</b> | 329,18          | 27,9           | 23497         | 1322            | 324            | 29192,8          | 5695,8                |                     | 329,18          | 26,81          | 24495         | 0                   | 41                 | 27480,95         | 2985,95               |                 |

Berdasarkan tabel 2 di atas, selain beberapa duplikasi data yang di outlier, ada beberapa variabel juga yang di outlier diantaranya: Department, Target Plan, Recruitment, Retirement, dan Forecast Summary untuk dilakukan proses atribut seleksi seperti yang tertera pada Tabel 3.

### 3.1.2.2 Atribut Seleksi (Selection Attributes)

Data yang disiapkan berasal dari data terbuka yang dihasilkan sesuai dengan persyaratan atribut. Pemilihan atribut penting yang akan digunakan. Tidak semua atribut mungkin relevan untuk analisis. Atribut yang dipilih berkontribusi paling besar terhadap tujuan analisis, dan mengurangi ukuran dan dimensi data untuk mempercepat proses. (Sasikumar & Kumaravel, 2019). Adapun hasil sampel seleksi atribut pada tahapan ini terdapat pada tabel 3, sebagai berikut:

Tabel 3. Sample Data Attribute Variabel

| Month    | Year | Attribute<br>Month | Attribute<br>Performance | AttributeTotal Head<br>Count (HC) | Attribute<br>Target<br>Actual | Attribute<br>Forecast<br>Value |
|----------|------|--------------------|--------------------------|-----------------------------------|-------------------------------|--------------------------------|
| January  | 2020 | Jan-20             | 11,51                    | 21895                             | 20549                         | -1346                          |
| .....    |      |                    |                          |                                   |                               |                                |
| December | 2022 | Dec-22             | 12,83                    | 29433                             | 31494                         | 2061                           |

Pada tabel 3 di atas, merupakan atribut data untuk persiapan dilakukan transformasi data.

### 3.1.2.3 Transformasi Data (Data Transformation)

Meliputi normalisasi, pengkodean variabel kategoris, pemenuhan nilai yang hilang, dan perhitungan Total Head Count yang diperoleh dari perhitungan rumus. (Junaedi et al., 2011). Data yang ditransformasikan adalah data sampel, dan diambil kesimpulan data yang terdiri dari data nilai kinerja KPI rata-rata, data rekrutmen, data pensiun, dan target rencana turnover bulan berjalan (input manual oleh Admin/user di setiap departemen untuk mengetahui kebutuhan karyawan di setiap departemen). Berikut ini akan dibahas perhitungan manual dari komponen data yang dibutuhkan untuk menyusun prediksi *Man Power Planning* (MPP), sebagai berikut:

$$\text{Performance KPI} = \frac{\text{Performance Data}}{6 \text{ Months}} \quad (2)$$

$$\text{Total Head Count} = \Sigma \text{Total All In MPP} + \Sigma \text{Total Hourly MPP} \quad (3)$$

$$\text{Total Retirement} = \Sigma \text{Total All In Retirement MPP} + \Sigma \text{Total Retirement Hourly MPP} \quad (4)$$

$$\text{Actual Target} = \text{Target Plan} \times (\Sigma \text{Total Head Count} + \Sigma \text{Total Recruitment} \Sigma \text{Total Retirement}) \quad (5)$$

$$\text{Forecast Value} = \text{Target Actual} - (\Sigma \text{Total Head Count} + \Sigma \text{Total Recruitment} - \Sigma \text{Total Retirement}) \quad (6)$$

Hasil Transformasi data yang kemudian akan dilakukan pengujian data menggunakan RapidMiner adalah sebagai berikut:

Tabel 4. Sample Data untuk Transformasi Data

| Month  | Performance | Total HC | Target Actual | Forecast Value |
|--------|-------------|----------|---------------|----------------|
| Jan-20 | 11,51       | 21895    | 20549         | -1346          |
| .....  |             |          |               |                |
| Dec-22 | 12,83       | 29433    | 31494         | 2061           |

Tabel 4 merupakan hasil transformasi data sebelum dilakukan Pengujian Data dengan RapidMiner.

### 3.1.3 Pengujian Data Dengan RapidMiner (Data Testing with RapidMiner)

Terdapat beberapa langkah dalam Testing Data dengan RapidMiner, yaitu sebagai berikut: 1. Prepare Data: Load dataset ke dalam RapidMiner. Pastikan dataset memiliki struktur yang sama dengan data training Anda, termasuk variabel target; 2. Import Model: Model yang digunakan Autoregressive (AR), Integrated (I), dan Moving Average (MA) yang digunakan untuk peramalan dengan data time series; 3. Load Test Data: Gunakan operator "Read Excel," "Read CSV," atau operator lain yang sesuai untuk memuat data test ke dalam RapidMiner; 4. Data Preprocessing: Memastikan data test memiliki format dan struktur yang sama dengan data yang digunakan untuk melatih model; 5. Apply Model to Forecast Model (ARIMA): Ini akan menghasilkan prediksi berdasarkan data test; 6. Evaluate Model Performance: Untuk mengevaluasi kinerja model data pada data test, kemudian menggunakan operator evaluasi yang sesuai (Apply Forecast); 7. Visualize Results (Chart/Visualisasi Data): Operator visualisasi membuat chart, grafik, atau matriks konfusi yang menginterpretasikan hasil dari model data test; 8. Analisis Hasil: Analisis metrik kinerja untuk memahami bagaimana model digeneralisasi ke data baru yang tidak terlihat. Jika kinerja data pengujian konsisten dengan kinerja data pelatihan, itu merupakan tanda yang baik bahwa model tidak overfitting; 9. Iterasi: Jika data hasil tidak sesuai dengan beberapa pola dan ditunjukkan sebagai model yang tidak akurat, maka harus diuji ulang sebagai data proses iteratif untuk melakukan praproses data, hingga mendapatkan beberapa pola dan model data. (Aprilla C et al., 2013)

#### 3.1.3.1 Analisis Hasil (Result Analysis)

Langkah ini adalah untuk menemukan pengetahuan yang tersirat dan berguna dari kumpulan data besar menggunakan teknik visualisasi data dan/atau pengetahuan. Sistem visual manusia dikendalikan oleh mata dan otak, yang terakhir dapat dianggap sebagai mesin pemrosesan dan penalaran paralel yang kuat yang berisi basis pengetahuan yang besar. Penambahan data visual pada dasarnya menggabungkan kekuatan komponen-komponen ini, menjadikannya alat yang sangat menarik dan efektif untuk memahami distribusi data, pola, kluster, dan outlier dalam data. (Han et al., 2011)

## 4 Hasil dan Pembahasan

### 4.1 Pengumpulan Data (Data Collection)

Sumber data diperoleh dari website mackaro.com. Rentang data yang dikumpulkan dengan time series dari tahun 2020 sampai dengan tahun 2022 sebanyak 2.000 data yang diperoleh dari website mackaro.com. Data yang dikumpulkan berasal dari penarikan dataset dari satu perusahaan manufaktur. Ada beberapa langkah yang dilakukan selama proses pengumpulan data, sebagai berikut: Mengumpulkan Dataset Karyawan, Dataset Kinerja KPI, Dataset Rekrutmen, Dataset Pensiun, Dataset Target Plan Man Power Planning (MPP), Memilih atribut penting, menghapus atribut yang tidak diperlukan, Menghitung rata-rata skor KPI Kinerja di setiap bulan, Menghitung Realisasi Target dari Target Plan, Jumlah Karyawan, Ringkasan Skor KPI Kinerja, Jumlah Karyawan, Jumlah Rekrutmen, dan Pensiun di setiap bulan. Terdapat beberapa langkah yang dilakukan dalam proses pengumpulan data, yaitu: 1. Mengumpulkan dataset karyawan, 2. Mengumpulkan dataset KPI Kinerja, 3. Mengumpulkan dataset Rekrutmen, 4. Mengumpulkan dataset Pensiun, 5. Mengumpulkan dataset Target Plan Man Power Planning (MPP), 6. Memilih atribut penting dan membuang atribut yang tidak diperlukan, 7. Menghitung rata-rata skor KPI Kinerja setiap bulan. 8. Menghitung Realisasi Target Plan dan Total Head Count. 9. Menghitung Ringkasan Skor KPI Kinerja, Total Head Count, Total Rekrutmen, dan Pensiun setiap bulan. Rentang data yang dikumpulkan dengan time series dari tahun 2020 sampai dengan tahun 2023. Beberapa data yang belum rampung pada tahun 2023 dan data yang akan diproses adalah dataset tahun 2020 sampai dengan tahun 2022, dan diuraikan pada Tabel 5.

Tabel 5. Pengumpulan Data

| Department | MM-YYYY     |             |            |             |            |               |                |
|------------|-------------|-------------|------------|-------------|------------|---------------|----------------|
|            | Performance | Target Plan | Head Count | Recruitment | Retirement | Target Actual | Forecast Value |

| Department               | MM-YYYY     |             |            |             |            |               |                |
|--------------------------|-------------|-------------|------------|-------------|------------|---------------|----------------|
|                          | Performance | Target Plan | Head Count | Recruitment | Retirement | Target Actual | Forecast Value |
| Plant A                  | 14.67       | 0.93        | 1318       | 0           | 0          | 1226          | -92            |
| Plant B                  | 9.33        | 0.93        | 1654       | 11          | 0          | 1548          | -117           |
| Plant C                  | 9.83        | 0.93        | 3600       | 0           | 0          | 3348          | -252           |
| Plant D                  | 12.50       | 0.93        | 1309       | 0           | 1          | 1216          | -92            |
| Plant E                  | 8.83        | 0.93        | 2487       | 0           | 0          | 2313          | -174           |
| Plant F                  | 12.67       | 0.93        | 2945       | 0           | 0          | 2739          | -206           |
| Plant G                  | 12.50       | 0.93        | 1637       | 0           | 0          | 1522          | -115           |
| Plant H                  | 9.33        | 0.93        | 1616       | 0           | 1          | 1502          | -113           |
| Plant I                  | 11.33       | 0.93        | 1412       | 0           | 0          | 1313          | -99            |
| Plant J                  | 9.33        | 0.93        | 1635       | 8           | 0          | 1528          | -115           |
| Business Development     | 10.33       | 1           | 102        | 0           | 0          | 102           | 0              |
| Legal                    | 11.50       | 1           | 6          | 0           | 0          | 6             | 0              |
| Support                  | 10.33       | 1           | 30         | 0           | 0          | 30            | 0              |
| Research and Development | 12.83       | 1           | 50         | 5           | 0          | 55            | 5              |
| Engineering              | 9.33        | 1           | 100        | 0           | 0          | 100           | 0              |
| Human Resources          | 13.67       | 1           | 234        | 0           | 0          | 234           | 0              |
| Accounting               | 8.33        | 1           | 10         | 0           | 0          | 10            | 0              |
| Marketing                | 13.00       | 1           | 200        | 0           | 0          | 200           | 0              |
| Training                 | 10.83       | 1           | 10         | 0           | 0          | 10            | 0              |
| Product Management       | 8.67        | 1           | 189        | 0           | 0          | 189           | 0              |
| Sales                    | 14.00       | 1           | 324        | 0           | 0          | 324           | 0              |
| Services                 | 14.83       | 1           | 57         | 0           | 0          | 57            | 0              |
| IT                       | 12.33       | 1           | 70         | 1           | 0          | 71            | 1              |
| GA                       | 14.67       | 1           | 200        | 0           | 0          | 200           | 0              |
| Production Planning      | 12.67       | 1           | 700        | 5           | 0          | 705           | 5              |
| TOTAL                    | 11.51       | 0           | 21895      | 30          | 2          | 20549         | -1346          |

#### 4.2 Pra Proses (Preprocessing)

Terkait dengan Tabel 2 di atas, Data kinerja merupakan nilai rata-rata karyawan di setiap departemen yang dibagi dalam 6 bulan, dan akan menghasilkan nilai rata-rata untuk setiap bulannya. Data kinerja diperlukan untuk memberikan informasi tentang nilai rata-rata kompetensi kapabilitas setiap karyawan di setiap departemen, sehingga apabila ada departemen yang nilai skornya berada di bawah ekspektasi, maka akan dipertimbangkan untuk menambah atau mengurangi karyawan yang dibutuhkan di departemen tersebut. Sebelum melakukan pengujian data dengan RapidMiner, sebaiknya dibuat ringkasan data seperti pada Tabel 3.

Tabel 6. Ringkasan Dataset sebagai Pengujian Data untuk RapidMiner


| Month  | Performance | Total HC | Target Actual | Forecast Value |
|--------|-------------|----------|---------------|----------------|
| Jan-20 | 11.51       | 21895    | 20549         | -1346          |
| Feb-20 | 11.51       | 21939    | 32193         | 10254          |
| Mar-20 | 11.51       | 21258    | 21504         | 246            |
| Apr-20 | 11.51       | 21714    | 22603         | 889            |
| May-20 | 11.51       | 21540    | 21430         | -110           |
| Jun-20 | 11.51       | 21425    | 23472         | 2047           |
| Jul-20 | 13.17       | 23499    | 24003         | 504            |
| Aug-20 | 13.17       | 24495    | 29193         | 4698           |
| Sep-20 | 13.17       | 24454    | 27481         | 3027           |
| Oct-20 | 13.17       | 25278    | 27732         | 2454           |
| Nov-20 | 13.17       | 27303    | 23029         | -4274          |
| Dec-20 | 13.17       | 27210    | 27262         | 52             |

Tabel 6 di atas merupakan Kumpulan data Ringkasan Rangkaian Waktu ini disiapkan sebagai Pengujian Data yang akan diimpor ke RapidMiner dengan Model Peramalan ARIMA. Rangkaian waktu ini harus memiliki waktu tertentu dan tidak dapat diduplikasi. dan perhitungan manual yang telah kita lakukan sebelumnya, akan menjadi target aktual dan akan dihitung secara otomatis dengan model ARIMA untuk meramalkan skor selama 12 bulan kemudian. Pada bagian ini, data yang telah dikumpulkan harus dipilih di mana atribut penting atau tidak penting untuk mempermudah saat memproses data. Ada beberapa langkah untuk memilih atribut penting.

#### 4.3 Pengujian Data dengan RapidMiner

Pengujian data melibatkan evaluasi kinerja model atau analisis pada data baru yang belum pernah dilihat sebelumnya untuk menilai efektivitas dan kemampuan generalisasinya. Data yang diperoleh dari perhitungan manual kemudian diinterpretasikan ke dalam alat pemrosesan Data Mining menggunakan RapidMiner. Pendekatan ini diambil untuk menunjukkan bahwa platform tersebut dapat memenuhi kebutuhan analisis prediktif para pengambil keputusan tanpa keterampilan pemrograman. (Togatorop et al., 2023) Ada beberapa langkah dalam Testing Data dengan RapidMiner, yaitu sebagai berikut: 1. Prepare Data: Load dataset ke dalam RapidMiner. Pastikan dataset memiliki struktur yang sama dengan data training Anda, termasuk variabel target; 2. Import Model: kita menggunakan Autoregressive (AR), Integrated (I), dan Moving Average (MA) yang digunakan untuk peramalan dengan data time series; 3. Load Test Data: Gunakan operator "Read Excel," "Read CSV," atau operator lain yang sesuai untuk memuat data test Anda ke dalam RapidMiner; 4. Data Preprocessing: Pastikan data test memiliki format dan struktur yang sama dengan data yang digunakan untuk melatih model; 5. Apply Model to Forecast Model (ARIMA): Ini akan menghasilkan prediksi berdasarkan data test; Evaluate Model Performance: Untuk mengevaluasi kinerja model data pada data test, gunakan operator evaluasi yang sesuai (Apply Forecast); 7. Visualize Results (Chart/Visualisasi Data): Operator visualisasi membuat chart, grafik, atau matriks konfusi yang menginterpretasikan hasil dari model data test; 8. Analisis Hasil: Analisis metrik kinerja untuk memahami bagaimana model digeneralisasi ke data baru yang tidak terlihat. Jika kinerja data pengujian konsisten dengan kinerja data pelatihan, itu pertanda baik bahwa model tidak overfitting; 9. Iterasi: Jika data hasil tidak sesuai dengan beberapa pola dan ditampilkan sebagai model yang tidak akurat, data tersebut harus diuji ulang sebagai data proses iteratif untuk melakukan praproses data, hingga beberapa pola dan model data. Gambar 2 di bawah ini, adalah tangkapan layar tentang bagaimana kumpulan data yang kami siapkan sebelumnya, diimpor ke RapidMiner:






Gambar 2. Pemrosesan Data Mining menggunakan RapidMiner

Gambar 2 di atas menunjukkan bahwa langkah pertama untuk menguji data ke RapidMiner, harus mengimpor dataset dalam File Excel dan memastikan validasi data tidak salah. Setelah itu, cari ARIMA di kotak operasi dan lakukan relasi dengan dataset yang diimpor. Autoregressive (AR), Integrated (I), dan Moving Average (MA), atau ARIMA menggambarkan deret waktu dengan jumlah tertimbang dari nilai deret waktu yang tertinggal (istilah Autoregressive) dan jumlah tertimbang dari residual yang tertinggal. nilai deret waktu asli harus berbeda dan unik dan label harus memiliki nilai numerik. Setelah itu cari operasi Apply Forecast untuk mengimplementasikan metode peramalan ARIMA. Apply Forecast juga digunakan untuk memprediksi nilai baru. Operator Apply Forecast memerlukan Dataset yang kompatibel dengan model. Karena model peramalan deret waktu sangat bergantung pada data yang dipasangnya, data ini sudah termasuk dalam model peramalan. Kemudian setelah memeriksa validasi sudah benar, kita dapat menjalankan proses data tersebut. Kemudian metode ARIMA sebagai algoritma untuk meramalkan Man Power Planning akan menunjukkan prediksi selama 12 bulan kemudian di Tabel 4, sebagai berikut:

Tabel 7. Hasil Ramalan di RapidMiner dengan metode ARIMA

| Month  | Forecast Man Power Planning (MPP) |
|--------|-----------------------------------|
| Jan-23 | 1223                              |
| Feb-23 | 1253                              |
| Mar-23 | 1253                              |
| Apr-23 | 1252                              |
| May-23 | 1252                              |
| Jun-23 | 1252                              |
| Jul-23 | 1252                              |
| Aug-23 | 1252                              |
| Sep-23 | 1252                              |
| Oct-23 | 1252                              |
| Nov-23 | 1252                              |
| Dec-23 | 1252                              |

Prediksi untuk 12 bulan setelah deret waktu terakhir adalah hasil Tabel 4 di atas. ARIMA dan Apply Forecast memberikan prediksi yang mungkin untuk 12 bulan setelahnya dan secara otomatis dihitung dengan metode ini. Visualisasi hasil Forecast Man Power Planning diperoleh seperti yang ditunjukkan pada Gambar 3.



Gambar 3. Visualisasi Grafik Garis Pengolahan Data Prakiraan MPP Menggunakan RapidMiner

Gambar 3 di atas menunjukkan bahwa grafik berwarna orange dengan label Forecast Value merupakan data realisasi Target Aktual pada Total All Employees pada bulan tersebut. Grafik berwarna hijau dengan label Forecast Value dan Forecast menunjukkan nilai prediksi untuk 12 bulan ke depan mengenai data time series. Sedangkan grafik berwarna biru menunjukkan nilai prediksi untuk beberapa bulan kedepan. Hal ini tentunya memberikan kita pemahaman dan pengetahuan untuk memprediksi berapa orang yang seharusnya direncanakan tenaga kerjanya dan masing-masing departemen pada bulan tersebut dan bulan-bulan yang akan datang. Hasil ramalan Metode ARIMA pada Gambar 3 menjelaskan bahwa visualisasi tersebut menggabungkan Target Aktual dari Actual Plan dan Trend Time Series yang ada pada setiap bulan yang telah dihitung sebelumnya. Plot garis yang melapiskan data historis aktual dengan nilai ramalan. Plot ini membantu seberapa baik secara visual model ARIMA dalam menangkap tren historis dan fluktuasi pada data.

#### 4.4 Analisis Hasil (Result Analysis)

Hasil dari pengolahan data yang tertera pada Tabel 7 menunjukkan bahwa kebutuhan man power planning di bulan januari hingga maret 2023 sebanyak 1253, dan di bulan april hingga desember 2023 kebutuhan man power planning sebanyak 1252. Hasil ini menunjukkan bahwa terjadi penurunan kebutuhan man power planning. Dan pada gambar 3 pun menunjukkan forecast nilai kebutuhan cenderung bernilai stabil karena memiliki nilai yang sama dalam kurun waktu beberapa bulan terakhir.

## 5 Kesimpulan

Kesimpulannya, pengolahan data mining menggunakan RapidMiner membantu perusahaan manufaktur meramalkan kebutuhan tenaga kerja di masa mendatang, mengoptimalkan penggunaan sumber daya manusia, dan membuat keputusan yang lebih baik. Hal ini memberikan keunggulan kompetitif dan membantu perusahaan untuk lebih tanggap memberikan saran dalam membuat keputusan terkait kebutuhan karyawan dan rencana mereka. Hasil menunjukkan bahwa hasil Prediksi Target Aktual Jumlah Karyawan memiliki nilai yang lebih tinggi daripada data Prediktif dari data Target Aktual untuk 12 bulan ke depan. Itu berarti peramalan dalam data Man Power Planning dalam penelitian ini sudah berhasil diterapkan di Perusahaan Manufaktur.

## Referensi

- Aprilla C, D., Baskoro, D. A., Ambarwati, L., & Wicaksana, I. W. S. (2013). *Identitas Belajar Data Mining dengan RapidMiner* (R. Sanjaya, Ed.; 1st ed., Vol. 1).
- Arifin, N., Saputra, E., Khairil Ahsyar, T., & Muttakin, F. (2023). Audit Keamanan Sistem Informasi Euclid Menggunakan Framework Cobit 5 pada PT. XYZ. *Jurnal Informatika Polbeng*, 8(1), 2023.
- Ariyanto, F., & Tamam, M. B. (2020a). ANALISIS TIME SERIES DENGAN METODE ARIMA DAN APLIKASINYA. *Jurnal JATIM*, 01(02).
- Ariyanto, F., & Tamam, Moh. B. (2020b). ANALISIS TIME SERIES DENGAN METODE ARIMA DAN APLIKASINYA. *Jurnal Aplikasi Teknologi Informasi Dan Manajemen (JATIM)*, 1(2), 26–36. <https://doi.org/10.31102/jatim.v1i2.972>

- Box, G., Jenkins, G., Reinsel, G., & Ljung, G. (2015). *Time series analysis: forecasting and control*. <https://books.google.com/books?hl=en&lr=&id=rNt5CgAAQBAJ&oi=fnd&pg=PR7&ots=DKa2sTmWTx&sig=ZtYxv6pBIUSOFrCvpi6ZkN-Rk0c>
- Bozarth, C., Handfield, R., & Weiss, H. (2008). *Introduction to operations and supply chain management* (Third Edition). <http://ndl.ethernet.edu.et/bitstream/123456789/23257/1/2%202013.pdf>
- Brockwell, P., & Davis, R. (2009). *Time series: theory and methods*. <https://books.google.com/books?hl=en&lr=&id=TVlpBgAAQBAJ&oi=fnd&pg=PA1&dq=+Brockwell+PJ,+Davis+RA.+Time+series:+theory+and+method.+Berlin:+Springer-Verlag,+1987.&ots=nl5A8CkiV-&sig=Wi938aKxQhORozQpqn0n8mPMsYg>
- Buulolo, M., Hawa, R., Sinaga, A., & Partogi, T. (2023). ANALISIS PERENCANAAN DAN PENGAWASAN BIAYA PRODUKSI PADA PERUSAHAAN MANUFAKTUR YANG TERDAFTAR DI BURSA EFEK INDONESIA (BEI) PERIODE 2019-2021. *JURNAL GLOBAL MANAJEMEN*, 12(1), 24–28. [www.idx.co.id](http://www.idx.co.id).
- Diqi, M., Sahal, A., & Nur Aini, F. (2023). Multi-Step Vector Output Prediction of Time Series Using EMA LSTM. *Jurnal Online Informatika*, 8(1), 107–114. <https://doi.org/10.15575/join.v8i1.1037>
- Febriyanti, A. N., & Rifai, N. A. K. (2022). Metode Triple Exponential Smoothing Holt-Winters untuk Peramalan Jumlah Penumpang Kereta Api di Pulau Jawa. *Bandung Conference Series: Statistics*, 2(2). <https://doi.org/10.29313/bcss.v2i2.3560>
- Hamilton, James. D. (1994). *Time Series Analysis*. In *Princeton University Press* (First Edition). [https://books.google.co.id/books?hl=en&lr=&id=BeryDwAAQBAJ&oi=fnd&pg=PP1&dq=Hamilton+JD.+Time+series+analysis.+Princeton:+Princeton+University+Press,+1994.&ots=BgFR129Scr&sig=UIWaBt5D3hNVAjAC0Q7zVXKuYhw&redir\\_esc=y#v=onepage&q=Hamilton%20JD.%20Time%20series%20analysis.%20Princeton%3A%20Princeton%20University%20Press%2C%201994.&f=false](https://books.google.co.id/books?hl=en&lr=&id=BeryDwAAQBAJ&oi=fnd&pg=PP1&dq=Hamilton+JD.+Time+series+analysis.+Princeton:+Princeton+University+Press,+1994.&ots=BgFR129Scr&sig=UIWaBt5D3hNVAjAC0Q7zVXKuYhw&redir_esc=y#v=onepage&q=Hamilton%20JD.%20Time%20series%20analysis.%20Princeton%3A%20Princeton%20University%20Press%2C%201994.&f=false)
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining. Concepts and Techniques, 3rd Edition (The Morgan Kaufmann Series in Data Management Systems)*.
- John, D. R., & Latupeirissa, S. J. (2021). PERAMALAN HARGA EMAS DI INDONESIA TAHUN 2014-2019 DENGAN METODE ARIMA BOX-JENKINS. *VARIANCE: Journal of Statistics and Its Applications*, 2(2). <https://doi.org/10.30598/variancevol2iss2page53-62>
- Junaedi, H., Budianto, H., Maryati, I., & Melani, Y. (2011). Data Transformation pada Data Mining. *Prosiding Konferensi Nasional Inovasi Dalam Desain Dan Teknologi*, 7.
- Kabul, E. R., & Febrianto, M. N. (2022). Implementasi Metode Full Time Equivalent (FTE) Dalam Analisis Kebutuhan Tenaga Kerja. *IKRAITH-EKONOMIKA*, 5(1), 162–168.
- Kendall, M. G., Box, G. E. P., & Jenkins, G. M. (1971). Time Series Analysis, Forecasting and Control. *Journal of the Royal Statistical Society: Series A (General)*, 134(3), 450–453. <https://doi.org/10.2307/2344246>
- Komara, M. A., Yusuf, R. A., Salim, A. Y., Wahyuni, R. S., & Heryana, G. (2023). Rancang Bangun Sistem PPIC (Production Planning and Inventory Control) CV. DEA AYU LESTARI. *Journal of Applied Mechanical Technology*, 2(1), 42–50. <https://doi.org/10.31884/jamet.v2i1.28>
- Matsumoto, M., & Ikeda, A. (2015). Examination of demand forecasting by time series analysis for auto parts remanufacturing. *Journal of Remanufacturing*, 5(1). <https://doi.org/10.1186/S13243-015-0010-Y>
- Maulana, H. A. (2018). PEMODELAN DERET WAKTU DAN PERAMALAN CURAH HUJAN PADA DUA BELAS STASIUN DI BOGOR. *Jurnal Matematika Statistika Dan Komputasi*, 15(1). <https://doi.org/10.20956/jmsk.v15i1.4424>
- Nugroho, K., Wismarini, Th. D., & Murti, H. (2023). Sales Conversion Optimization Analysis Using the Random Forest Method. *Sinkron*, 8(4). <https://doi.org/10.33395/sinkron.v8i4.12943>
- Prasasti Dewi, N. M. I. F., & Wirasuta, I. M. A. G. (2021). STUDI PERENCANAAN PENGADAAN SEDIAAN FARMASI DI APOTEK X BERDASARKAN PERATURAN MENTERI KESEHATAN

- NOMOR 73 TAHUN 2016. *Indonesian Journal of Legal and Forensic Sciences (IJLFS)*, 11(1).  
<https://doi.org/10.24843/ijlfs.2021.v11.i01.p01>
- Rizqi, D. S., & Nabila, R. A. (2022). DETERMINASI KINERJA KARYAWAN: SUMBER DAYA MANUSIA, KOMITMEN DAN MOTIVASI KERJA (LITERATUR REVIEW MSDM). *JURNAL MANAJEMEN PENDIDIKAN DAN ILMU SOSIAL*, 3(2), 500–508.  
<https://doi.org/10.38035/jmpis.v3i2.1113>
- Roh, Y., Heo, G., & Whang, S. E. (2021). A Survey on Data Collection for Machine Learning: A Big Data-AI Integration Perspective. In *IEEE Transactions on Knowledge and Data Engineering* (Vol. 33, Issue 4, pp. 1328–1347). IEEE Computer Society.  
<https://doi.org/10.1109/TKDE.2019.2946162>
- Safitri, B. A., Iriany, A., & Wardhani, N. W. S. (2021). Perbandingan Akurasi Peramalan Curah Hujan dengan menggunakan ARIMA, Hybrid ARIMA-NN, dan FFNN di Kabupaten Malang. *Seminar Nasional Official Statistics*, 2021(1).  
<https://doi.org/10.34123/semnasoffstat.v2021i1.853>
- Sasikumar, C. S., & Kumaravel, A. (2019). E-learning attributes selection through rough set theory and data mining. *International Journal of Innovative Technology and Exploring Engineering*, 8(10). <https://doi.org/10.35940/ijitee.J9917.0881019>
- Sidqi, F., & Sumitra, I. D. (2019). PERAMALAN PENJUALAN BARANG SINGLE VARIANT MENGGUNAKAN METODE ARIMA, TREND ANALYSIS, DAN SINGLE EXPONENTIAL SMOOTHING (STUDI KASUS : TOKO SWALAYAN XYZ). *Jurnal Tata Kelola Dan Kerangka Kerja Teknologi Informasi*.
- Togatorop, A. R. M., Bahari, A. I. L., & Choiruddin, A. (2023). Neural Networks-Based Forecasting Platform for EV Battery Commodity Price Prediction. *INTENSIF: Jurnal Ilmiah Penelitian Dan Penerapan Teknologi Sistem Informasi*, 7(2), 243–261.  
<https://doi.org/10.29407/intensif.v7i2.19999>
- Utami, R., Ananda, V., & Sari, A. M. (2023). Peramalan Harga Minyak Mentah Dunia dengan Metode ARIMA dan Regresi Linier. *Prosiding Seminar Pendidikan Matematika Dan Matematika*, 7. <https://doi.org/10.21831/pspmm.v7i1.269>
- Wisner, J., Tan, K., & Leong, G. (2014). *Principles of supply chain management: A balanced approach*. [https://books.google.com/books?hl=en&lr=&id=yTN-BAAAQBAJ&oi=fnd&pg=PP1&ots=ZaHaZ346U6&sig=9fhOhXuC-\\_poZGazy0EmQRv87jE](https://books.google.com/books?hl=en&lr=&id=yTN-BAAAQBAJ&oi=fnd&pg=PP1&ots=ZaHaZ346U6&sig=9fhOhXuC-_poZGazy0EmQRv87jE)
- Wold, H. (1938). *A study in the analysis of stationary time series*. <https://www.diva-portal.org/smash/record.jsf?pid=diva2:492042>
- Zaky, F. A., Farhana, Yusuf, H., Rambe, K. F., Sufni, N., & Akmalia, R. (2023). Implementasi Pendekatan Ketenagakerjaan Dalam Perencanaan Pendidikan Di Pondok Pesantren (Madrasah Aliyah) Nurul Fadhillah. *Ar-Raudah : Jurnal Pendidikan Dan Keagamaan*, 2(1), 53–59. <https://ojs.staira.ac.id/index.php/raudah>