

## 2. TEORI PENUNJANG

### 2.1 . Tinjauan Pustaka

Pada bagian ini, teori-teori yang akan digunakan dalam penulisan skripsi maupun pembuatan sistem akan dijabarkan.

#### 2.1.1 Prediksi (*Forecasting*)

Secara umum, prediksi atau peramalan adalah proses perkiraan atau estimasi terhadap apa yang mungkin terjadi di masa depan. Namun, ada beberapa definisi peramalan menurut para ahli. Menurut Heizer dan Render peramalan (*forecasting*) adalah suatu seni dan ilmu pengetahuan dalam memprediksi peristiwa pada masa mendatang. Peramalan akan melibatkan pengambilan data historis (penjualan tahun lalu) dan memproyeksi mereka ke masa yang akan datang dengan model matematika (Heizer & Render, 2015). Selanjutnya menurut Handoko, peramalan adalah suatu usaha untuk meramalkan kejadian di masa mendatang melalui pengujian keadaan di masa lalu. Esensi peramalan adalah perkiraan peristiwa – peristiwa di waktu yang akan datang atas dasar pola – pola di waktu yang lalu dan penggunaan kebijakan terhadap proyeksi – proyeksi dengan pola – pola di waktu yang lalu (Handoko, 2015).

Peramalan menjadi penting karena perusahaan harus membuat keputusan di tengah ketidakpastian. Oleh karena itu, peramalan yang disusun dengan analisis dan perhitungan akan lebih terpercaya daripada sekadar mengandalkan perkiraan tanpa dasar analitis (Syakura et al., 2016). Dalam manajemen operasional, peramalan digunakan untuk mengestimasi jumlah produk yang akan diminta oleh konsumen dalam jangka waktu tertentu. Ini membantu dalam merencanakan produksi atau persediaan produk.

Berdasarkan jangka waktu, peramalan dapat dikelompokkan menjadi tiga tipe, yaitu (Herjanto, 2008):

1. Peramalan jangka panjang adalah peramalan untuk periode waktu yang melampaui 18 bulan. Contohnya adalah peramalan yang digunakan dalam pengambilan keputusan terkait investasi, dan penelitian atau pengembangan.
2. Peramalan jangka menengah mencakup periode waktu antara 3 hingga 18 bulan. Contohnya adalah peramalan yang digunakan untuk merencanakan penjualan dan produksi

3. Peramalan jangka pendek melibatkan periode waktu kurang dari 3 bulan, seperti peramalan yang digunakan dalam perencanaan pembelian bahan baku dan penjadwalan kerja.

### **2.1.2. ARIMA (*Autoregressive Integrated Moving Average*)**

#### **2.1.2.1. Pengertian ARIMA**

*Autoregressive Integrated Moving Average* (ARIMA) merupakan metode *time series analytics* yang dikenal sebagai Box-Jenkins. Metode ini mewakili tiga pemodelan yaitu dari *autoregressive* (AR), *moving average* (MA), serta *autoregressive moving average model* (ARMA) (Rahmadayanti et al., 2015). ARIMA adalah model *Autoregressive Moving Average* (ARMA) yang tidak stasioner. Dikarenakan ARIMA merupakan model ARMA yang tidak stasioner maka dalam mengerjakannya perlu dilakukan stasioneritas. Dalam mengatasi ketidakstasioneran data ini dilakukan proses *differencing* agar data menjadi stasioner.

Model ARIMA terdiri dari tiga proses yaitu *autoregressive*, *integrates (differencing)*, dan *moving average* dengan order (p,d,q) dinotasikan ARIMA (p,d,q). Notasi ini digunakan untuk mendeskripsikan bentuk dari model ARIMA dengan parameter p adalah orde *Autoregressive* (AR), d adalah orde diferensiasi atau jumlah *differencing* dan q adalah orde dari *Moving Average* (MA) (Kobiela et al., 2022). Sebelum menerapkan metode ARIMA untuk peramalan, ada berapa langkah-langkah yang perlu diterapkan seperti, mengidentifikasi model data (uji stasioneritas) dan penentuan model

#### **2.1.2.2. Identifikasi Model**

Seperti yang sudah disampaikan sebelumnya bahwa ARIMA memerlukan data yang stasioner, maka dari itu perlu dilakukan uji stasioner data. Ketidakstasioneran dalam runtun waktu dapat meliputi *mean* yang tidak konstan, varian yang tidak konstan ataupun keduanya (Wulandari et al., 2019). Suatu data yang tidak stasioner harus diubah menjadi data stasioner dengan melakukan *differencing*, sebuah proses untuk menghitung perubahan atau selisih nilai observasi, data yang sudah di *differencing* akan diuji lagi apakah sudah stasioner atau belum apabila belum maka akan dilakukan proses *differencing* lagi hingga data benar-benar stasioner. Hal ini rumuskan dengan rumus :

$$Y'_t = y_t - y_{t-1} \quad (2.1)$$

Dimana :

$Y'_t$  = nilai deret berkala setelah *differencing*

$X_t$  = nilai deret berkala pada waktu  $t$

Apabila proses *differencing* masih gagal pada putaran pertama, maka pada putaran kedua diterapkan *differencing* berdasarkan nilai pada putaran pertama dan berlaku seterusnya. Setelah data Stasioner maka penetapan estimasi model ARIMA dapat dilakukan dengan cara melihat nilai dari plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation* (PACF) (Wulandari et al., 2019).

*Autocorrelation Function* (ACF) mengukur hubungan antara pengamatan saat ini dan pengamatan dari waktu sebelumnya (disebut "*lag*"). Plot ACF adalah grafik yang menunjukkan hubungan dengan menggambarkan seberapa kuat hubungan linier antara pengamatan pada waktu tertentu dan pengamatan pada periode sebelumnya  $t-k$  (ArunKumar et al., 2021).

$$ACF(y_t, y_{t-k}) = \text{covariance}(y_t, y_{t-k}) / \text{variance}(y_t) \quad (2.2)$$

Dimana :

$K = \text{lag}$

$Y_t$  = nilai pada waktu  $t$

*Partial Autocorrelation Function* (PACF) mempertimbangkan pengamatan yang berada di antara dua pengamatan pada waktu  $t$  dan  $t-2$  untuk mengukur korelasi langsung antara kedua pengamatan tersebut. PACF membantu kita mengidentifikasi hubungan langsung antara dua pengamatan pada waktu yang berbeda (ArunKumar et al., 2021).

$$PACF(y_t, y_{t-2}) = \text{covariance}(y_t, y_{t-2} | y_{t-1}) / \text{variance}(y_t | y_{t-1})^{1/2} \text{variance}(y_{t-2} | y_{t-1})^{1/2} \quad (2.3)$$

Dimana :

$K = \text{lag}$

$Y_t$  = nilai pada waktu  $t$

### 2.1.2.3. Penentuan Model

Setelah melakukan *differencing*, menghitung ACF dan PACF, maka selanjutnya adalah tahapan untuk menentukan model yang ada. Model ARIMA terbagi menjadi 3 model yaitu AR, I, MA.

Model *autoregressive* (AR) adalah model yang menggunakan nilai-nilai sebelumnya, yang disebut *lag*, untuk memprediksi nilai variabel di masa depan. Model ini umumnya digunakan untuk menganalisis dan menyimpan data historis. Bentuk persamaan dari model AR dapat dituliskan sebagai berikut (ArunKumar et al., 2021):

$$y_t = c + \theta_1 y_{t-1} + \theta_2 y_{t-2} + \dots + \theta_p y_{t-p} + \varepsilon_t \quad (2.4)$$

Dimana :

$c$  = nilai konstanta

$y_t$  = nilai variabel pada waktu ke  $t$

$\theta_i$  = koefisien *autoregressive*,  $i = 1, 2, 3, \dots, p$

$\varepsilon_t$  = nilai error pada waktu ke- $t$

Model *moving average* (MA) meramalkan nilai mendatang berdasarkan *error* yang sebelumnya telah diprediksi atau disebut residual *error*. Perumusan Model ini dirumuskan secara matematis sebagai berikut (Brockwell & Davis, 2002).

$$y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.5)$$

Dimana :

$\mu$  = nilai rata-rata konstanta

$\theta_i$  = merupakan parameter MA (*error* dari *autocorrelation*)

$\varepsilon_t$  = nilai *error* pada waktu ke- $t$

Model *autoregressive and moving average* (ARMA) ,merupakan gabungan dari model Model *autoregressive* (AR) dan Model *moving average* (MA), dirumuskan sebagai berikut (Brockwell & Davis, 2002)

$$y_t = \theta_0 + \theta_1 y_{t-1} + \theta_2 y_{t-2} + \dots + \theta_p y_{t-p} + \varepsilon_t - \omega_1 \varepsilon_{t-1} - \omega_2 \varepsilon_{t-2} - \dots - \omega_q \varepsilon_{t-q} \quad (2.6)$$

Dimana :

$y_t$  = nilai variabel pada waktu ke  $t$

$\theta_p$  = merupakan parameter  $p$

$\omega_q$  = merupakan parameter  $q$

$\varepsilon_t$  = nilai *error* pada waktu ke- $t$

Ketika kita menggabungkan model AR dan MA dengan proses *integration (differencing)*, kita mendapatkan model ARIMA dengan tiga parameter utama, yaitu  $p$ ,  $d$ , dan  $q$ . di mana  $p$ ,  $d$  dan  $q$  menunjukkan perintah *autoregresi*, *differencing* dan *moving average*. Secara matematis, model ini dapat dijabarkan sebagai berikut:

$$y_t = c + \theta_1 y_{t-1} + \theta_2 y_{t-2} + \dots + \theta_p y_{t-p} + \varepsilon_t + \omega_1 \varepsilon_{t-1} + \omega_2 \varepsilon_{t-2} + \dots + \omega_q \varepsilon_{t-q} \quad (2.7)$$

Dimana :

$c$  = konstanta

$y_t$  = nilai variabel pada waktu ke  $t$

$\theta_p$  = merupakan parameter p

$\omega_q$  = merupakan parameter q

$\varepsilon_t$  = nilai error pada waktu ke-t

#### 2.1.2.4. Karakteristik Model

Dalam pemodelan menggunakan metode ARIMA, terdapat beberapa kondisi karakteristik yang dapat menyebabkan model menghasilkan prediksi konstan atau mengikuti garis lurus tanpa variasi. Beberapa kondisi tersebut adalah (Hyndman & Athanasopoulos, 2018).:

- Jika  $c = 0$  dan  $d = 0$ , ramalan jangka panjang akan menuju nol.
- Jika  $c = 0$  dan  $d = 1$ , ramalan jangka panjang akan menuju suatu konstanta non-nol.
- Jika  $c = 0$  dan  $d = 2$ , ramalan jangka panjang akan mengikuti garis lurus.
- Jika  $c \neq 0$  dan  $d \neq 0$ , ramalan jangka panjang akan menuju rata-rata data.
- Jika  $c \neq 0$  dan  $d \neq 1$ , ramalan jangka panjang akan mengikuti garis lurus.
- Jika  $c \neq 0$  dan  $d \neq 2$ , ramalan jangka panjang akan mengikuti trend kuadratik.

Prediksi konstan bukanlah suatu bug, tetapi mencerminkan karakteristik data deret waktu yang diprediksi. Titik prediksi biasanya merupakan rata-rata dari distribusi observasi masa depan berdasarkan pengamatan masa lalu. Hal ini menunjukkan bahwa tidak ada tren, musiman, atau dinamika temporal yang signifikan dalam data tersebut. Oleh karena itu, prediksi yang datar bukanlah kesalahan, melainkan refleksi dari kurangnya tren, musiman, atau dinamika temporal dalam data yang dianalisis (Hyndman, 2012).

#### 2.1.3. SARIMA (Seasonal Autoregressive Integrated Moving Average)

Metode ARIMA memiliki kelemahan dalam menangani pola musiman atau efek musiman dalam data. Untuk mengatasi masalah ini, dikembangkanlah metode bernama *Seasonal Autoregressive Integrated Moving Average* (SARIMA). SARIMA dirancang khusus untuk mengolah data yang memiliki efek musiman dalam polanya (Vagropoulos et al., 2016). SARIMA memiliki parameter  $(p,d,q)(P,D,Q)m$ , sehingga dapat dinotasikan seperti

$$\text{SARIMA}(p,d,q)(P,D,Q)m \quad (2.8)$$

Dimana :

$(p, d, q)$  = orde AR, banyaknya differencing, orde MA

$(P, D, Q)$  = orde AR musiman, banyaknya differencing musiman, orde MA musiman

$m$  = jumlah periode per musim

Secara matematis, model SARIMA dapat dijabarkan sebagai berikut (Ginda & Suwandi, 2021),

$$\Phi_P(B^S)\phi_p(B)(1-B)^d(1-B^S)^D Z_t = \theta_q(B)\Theta_Q(B^S)\alpha_t \quad (2.9)$$

Dimana :

$\phi_p(B)$  = faktor AR *non*-musiman  
 $\Phi_p(B^S)$  = faktor AR musiman  
 $(1 - B)^d$  = nilai *differencing non*-musiman  
 $(1 - B^S)^D$  = nilai *differencing* musiman  
 $\theta_q(B)$  = faktor MA non-musiman  
 $\Theta_q(B^S)$  = faktor MA musiman  
 $Z_t$  = data aktual di waktu t  
 $\alpha_t$  = error di periode t

#### 2.1.4. Simple Exponential Smoothing (SES)

*Exponential Smoothing* adalah sebuah metode statistik yang menggunakan data masa lalu dalam rangka untuk memprediksi nilai di masa depan. Disebut "eksponensial" karena metode ini memberikan bobot berkurang secara eksponensial pada data-data masa lalu, sehingga data yang lebih baru memiliki pengaruh yang lebih besar daripada data yang lebih lama. Ini membuat metode ini responsif terhadap perubahan dalam data, sehingga dapat menangkap pola atau tren yang mungkin ada di dalamnya (Simplilearn, 2023). *Simple Exponential Smoothing*(SES) adalah bentuk paling dasar dari *Exponential Smoothing*. Metode ini hanya memanfaatkan data pengamatan saat ini dan perkiraan dari periode sebelumnya untuk membuat perkiraan berikutnya tanpa memikirkan trend maupun musim. Secara matematis, model ini dapat dijabarkan sebagai berikut:

$$F(t+1) = \alpha * Y(t) + (1 - \alpha) * F(t) \quad (2.10)$$

Dimana :

$\alpha$  = *alpha* / konstanta ( $0 < \alpha < 1$ )

$Y_t$  = data aktual periode t

$F_t$  = prediksi atau *forecast* untuk periode

#### 2.1.5. RMSE (Root Mean Square Error)

RMSE menghitung rata-rata dari selisih kuadrat antara nilai prediksi dan nilai aktual kemudian diambil akar kuadratnya. Semakin kecil nilai RMSE, semakin baik kualitas model tersebut (Trivusi, 2023) .Dimana :

$$RMSE = [(\sum (A_t - F_t)^2)/n]^{1/2} \quad (2.11)$$

RMSE = *Root Mean Square Error*

$N$  = jumlah data

$z_k$  = nilai sebenarnya

$z^k$  = nilai prediksi

#### **2.1.6. Klasifikasi ABC**

Analisis klasifikasi ABC adalah metode untuk mengelompokkan produk berdasarkan nilai kontribusinya terhadap penjualan atau keuntungan bisnis. Tujuan utamanya adalah untuk mengidentifikasi produk-produk yang memiliki nilai tinggi atau penting sehingga manajemen dapat memprioritaskan pengelolaan produk tersebut dibandingkan produk yang kurang bernilai. Klasifikasi ABC didasarkan pada premis bahwa tidak semua persediaan mempunyai nilai yang sama, sesuai dengan Prinsip Pareto yang menyatakan bahwa sekitar 20% item atau produk umumnya memberikan kontribusi sekitar 80% terhadap nilai penjualan atau profitabilitas. Dengan menggunakan klasifikasi ABC, Anda dapat membagi inventaris menjadi tiga kategori (Drakeley, 2021) .

Kriteria masing-masing kategori dalam klasifikasi ABC dapat dibagi sebagai berikut (Hamali et al., 2019):

1. Kelas A: Persediaan yang memiliki nilai volume tahunan rupiah yang tinggi. Kelas ini mewakili sekitar 60% – 80% biaya persediaan barang dan Memberikan kontribusi paling besar.
2. Kelas B: Persediaan dengan nilai volume tahunan rupiah yang menengah, kelas B yang mewakili 25% – 35% dari biaya persediaan barang.
3. Kelas C: Barang yang nilai volume tahunan rupiahnya rendah, yang hanya mewakili sekitar 5% – 15% biaya persediaan barang dan Memberikan kontribusi paling kecil

Tahapan yang dilakukan dalam pengklasifikasian berdasarkan metode ABC adalah sebagai berikut (Drakeley, 2021):

1. Membuat daftar produk, jumlah permintaan, dan harga masing-masing produk per tahun
2. Hitung jumlah unit terjual tahunan (per item) x biaya per *unit*
3. Buat daftar produk dalam urutan menurun berdasarkan nilai konsumsi tahunannya.
4. Jumlahkan jumlah *unit* yang terjual dan nilai konsumsi tahunan.
5. Hitung persentase kumulatif barang yang terjual dan persentase kumulatif nilai konsumsi tahunan dengan menggunakan totalnya.

6. Menentukan ambang batas pembagian data menjadi kategori A, B, dan C. Ambang batas untuk menentukan pemisahan ABC akan bersifat unik untuk perusahaan dan bauran produk Anda, namun biasanya mendekati 80% / 15% / 5%.

#### **2.1.7. Reorder Point**

Reorder Point (ROP), yang juga dikenal sebagai titik pemesanan kembali, adalah suatu konsep yang digunakan dalam manajemen persediaan untuk menentukan kapan seharusnya suatu pesanan pembelian atau produksi dilakukan untuk menggantikan persediaan yang telah digunakan atau terjual. ROP adalah titik kritis dalam pengendalian persediaan yang ditetapkan oleh perusahaan untuk memastikan bahwa persediaan bahan atau produk selalu tersedia saat dibutuhkan. Dalam menentukan Reorder Point memerlukan beberapa faktor seperti berikut (Rishani, 2019):

1. Safety Stock

Merupakan persediaan stok aman untuk mencegah terjadinya kemungkinan kekurangan barang saat permintaan mengalami lonjakan atau kondisi permintaan pasar sedang tidak menentu

2. Lead Time

Waktu tunggu yang didapat dari kapan barang dipesan hingga kapan barang yang dipesan dapat diterima. Berdasarkan faktor – faktor tersebut maka didapat rumus atau persamaan untuk menentukan Reorder Point sebagai berikut:

$$ROP = (D \times LT) + SS \quad (2.12)$$

Dimana :

SS = Safety Stock

LT = Lead Time

D = Rata-rata permintaan

#### **2.1.8. Safety Stock**

Safety Stock adalah suatu metode persediaan tambahan yang dilakukan untuk mencegah terjadinya kemungkinan kekurangan barang saat permintaan mengalami peningkatan pembelian atau keterlambatan pengiriman, tujuan dari safety stock adalah meminimalkan terjadinya kekurangan stok serta dapat mengurangi penambahan biaya penyimpanan (Rishani, 2019). untuk persamaan dapat dituliskan (Impulse Digital, 2023) :



$$\text{Safety Stock} = \text{Skor } Z \times \text{STD} \quad (2.13)$$

Dimana :

STD = Standar deviasi waktu

## 2.2. Tinjauan Studi

Pada bagian ini, penelitian-penelitian sebelumnya yang menjadi penunjang bagi skripsi ini akan dijabarkan.

### 2.2.1. Analisis Peramalan Penjualan Rokok SKT (Sigaret Kretek Tangan) Pada PT. Djitoe Indonesian Tobacco Coy. (Fauzi, 2009).

PT. Djitoe Indonesian Tobacco Coy Surakarta, sebagai salah satu pemain dalam industri pembuatan rokok, menghadapi beberapa tantangan serius. Pertama, perusahaan kesulitan meramalkan permintaan produk Rokok Kretek Tangan (SKT) dengan efektif, mengakibatkan ketidaksesuaian kuantitas dan kualitas produk dengan permintaan pasar. Kedua, munculnya pesaing-pesaing baru di kota solo mengakibatkan kemunduran bisnis apabila tidak menyesuaikan. Selain itu, perusahaan tampaknya bergantung pada pesanan atau supplier dalam proses produksinya, yang mungkin membuatnya lebih rentan terhadap fluktuasi dalam pesanan yang masuk.

Untuk mengatasi masalah ini peneliti mencoba untuk membuat analisis peramalan berdasarkan dataset penjualan rokok pada bulan maret tahun 2008 hingga Februari tahun 2009. Peneliti mengusulkan melakukan prediksi dengan menggunakan dua metode yang berbeda, *Exponential Smoothing* dan *Single Moving Averages*. Peneliti menggunakan metode *Exponential Smoothing* dengan menetapkan nilai alpha sebesar 0.1, 0.5, dan 0.9, yang nantinya akan dibandingkan efektifitasnya. Sedangkan untuk metode *moving average*, peneliti menggunakan perhitungan *moving average* sebanyak 3 bulan sekali, sehingga didapatkan rata-rata memperhitungkan nilai 3 bulan sekali. Pengujian penelitian ini adalah dengan meramalkan penjualan pada bulan maret 2023. Dalam analisis hasil peramalan, peneliti menyimpulkan bahwa metode *Exponential Smoothing* dengan  $\alpha = 0.1$  adalah metode yang paling baik. Metode ini menghasilkan ramalan yang memiliki *Mean Absolute Deviation* (MAD) dan *Mean Squared Error* (MSE) yang lebih rendah dibandingkan dengan metode *Exponential Smoothing* lainnya dan metode *Single Moving Averages*.

Kelebihan dari penelitian ini adalah adanya perbandingan antara dua metode sehingga peneliti dapat membandingkan kinerja mereka dalam meramalkan penjualan. Hal ini memberikan wawasan tentang mana yang lebih efektif dari kedua metode tersebut. Selain itu,

perhitungan yang dilakukan dalam penelitian ini disajikan secara manual sehingga hasilnya bisa dilihat dengan jelas dan rinci. Namun, Penelitian ini hanya menyajikan data penjualan dari tahun 2008-2009. Periode waktu yang singkat hanya 12 bulan ini mungkin tidak mencerminkan tren jangka panjang dalam industri rokok.

Berdasarkan kesimpulan dari penelitian sebelumnya, dalam tugas akhir ini akan dilakukan pengerjaan dengan menggunakan metode *Exponential Smoothing*. Metode ini dipilih karena menunjukkan tingkat *error* yang rendah dan juga karena fleksibilitasnya dalam meramalkan penjualan. Selain itu, metode ARIMA juga akan diikutsertakan dalam penelitian ini untuk membandingkan hasil akurasi peramalan. Pemilihan metode ARIMA didasari oleh penggunaan dataset yang mencakup periode 54 bulan, yang memungkinkan adanya tren penjualan tertentu yang dapat diidentifikasi dan dimodelkan. Selain itu, penelitian ini juga akan memberikan strategi bisnis dalam konteks peramalan guna memberikan wawasan yang lebih *complex*.

#### **2.2.2. Sales Forecasting by Using Exponential Smoothing Method and Trend Method to Optimize Product Sales in PT. Zamrud Bumi Indonesia During the Covid-19 Pandemic (Nirmala et al., 2021)**

Perusahaan PT. Zamrud Bumi Indonesia, yang bergerak dalam manajemen pupuk cair dengan merek "Power Bumi" menghadapi sejumlah masalah dalam operasional bisnisnya. Masalah utamanya adalah adanya fluktuasi dalam penjualan produk mereka, hal ini mengakibatkan penumpukan stok produk di gudang, manajemen inventaris yang tidak teratur, dan biaya manajemen inventaris yang meningkat, yang berujung pada ketidak-efisienan dan kerugian. Tidak hanya itu, efek dari pandemi covid-19 pada tahun 2020 juga membuat permintaan dan pasokan produk berkurang. Kehadiran perusahaan-perusahaan pesaing dalam industri yang sama atau munculnya pesaing baru menjadi faktor yang mengancam dan dapat mengakibatkan penurunan laba.

Untuk mengatasi masalah ini peneliti menggunakan dataset penjualan mulai dari mei 2020 hingga april 2021. Peneliti mengusulkan menggunakan metode *Exponential Smoothing* dengan  $\alpha$  0,1, 0,5, dan 0,9 dan juga *Trend Model Least Square* (TMLS). Kemudian hasil dari perhitungan tersebut di test dengan menggunakan metode *Mean Absolute Deviation* (MAD), *Mean Square Error* (MSE), *Mean Absolute Percentage Error* (MAPE). Dari perbandingan hasil, metode *Exponential Smoothing* dengan  $\alpha$  0,9 terbukti paling efektif dalam menghasilkan perkiraan penjualan yang akurat. Meskipun perkiraan ini tidak sangat akurat, namun sudah

termasuk baik jika dibandingkan dengan metode lain yang digunakan. Hasil penelitian dengan metode *Exponential Smoothing alpha* 0,9 menunjukkan bahwa penjualan diprediksi sebanyak 627,628, dengan MAD 130,329, MSE 28251,23, dan MAPE 22,004%. Nilai-nilai ini lebih rendah dibandingkan dengan metode lain.

Penelitian ini membandingkan dua metode peramalan dan menganalisis berbagai nilai *alpha* dalam metode *Exponential Smoothing*. Hasil menunjukkan perbedaan signifikan dalam hasil peramalan tergantung pada nilai *alpha*. Sebagai contoh, TMLS lebih baik daripada  $\alpha = 0,1$  dan  $\alpha = 0,5$ , sedangkan *Exponential Smoothing* lebih unggul pada  $\alpha = 0,9$ . Hal ini memberi wawasan lebih mendalam tentang penggunaan metode *exponential smoothing* dalam peramalan. Namun, penelitian ini terbatas oleh jumlah data yang terbatas, sehingga tren mungkin belum terlihat dengan jelas.

Berdasarkan kesimpulan dari penelitian diatas, tugas akhir ini akan menggunakan metode *Exponential Smoothing* dengan berbagai *alpha* dan ARIMA untuk peramalan penjualan. Penggunaan *Exponential Smoothing* didasarkan pada sejarahnya yang telah terbukti menghasilkan tingkat kesalahan rendah dan fleksibilitasnya. Penambahan metode ARIMA disebabkan oleh dataset yang mencakup 54 bulan, memungkinkan identifikasi dan pemodelan tren penjualan. Penelitian ini bertujuan memberikan pandangan lebih mendalam dalam konteks peramalan sebagai bagian dari strategi bisnis.

### **2.2.3. A Comparative Study on Forecasting of Retail Sales (Hasan et al., 2022)**

Dalam penelitian ini terdapat beberapa masalah yang dapat diidentifikasi. Masalah utama yang dihadapi oleh perusahaan besar seperti Walmart adalah tantangan dalam meramalkan penjualan produk mereka. Tantangan ini disebabkan oleh sifat yang fluktuatif dari tren penjualan, musiman, peristiwa tertentu, dan faktor-faktor tidak terduga seperti persaingan pasar, perubahan preferensi pelanggan, atau peristiwa tak terduga seperti wabah COVID-19. Perusahaan-perusahaan ini memiliki *volume* data yang sangat besar dan beragam, yang memerlukan analisis yang *complex* untuk menghasilkan wawasan yang berharga.

Penelitian ini menggunakan dataset dari Kaggle yang memuat data tentang penjualan di 10 toko Walmart di berbagai negara bagian Amerika Serikat. Dataset ini mencakup 3.049 produk yang dapat dikelompokkan menjadi tiga kategori utama yaitu hobi, makanan, dan rumah tangga. Dalam upaya mengatasi berbagai tantangan yang dihadapi, penulis melakukan perbandingan antara beberapa model peramalan, seperti ARIMA (*Autoregressive Integrated Moving Average*), *Prophet* yang dikembangkan oleh Facebook, dan *Light Gradient Boosting Machine* (LightGBM)

yang dikembangkan oleh Microsoft. Penelitian ini menggunakan metode *Root Mean Squared Error* (RMSE) sebagai pengukuran akurasi prediksi. Peneliti melakukan tes prediksi selama 28 hari ke depan dengan menggunakan 100 produk pada setiap kategori. Hasil prediksi menunjukkan bahwa ARIMA memberikan RMSE terendah (1.098577) dibandingkan dengan dua model lainnya. Namun, baik ARIMA maupun LightGBM memiliki kinerja yang baik dan memberikan nilai RMSE yang hampir sama (1.098577 dan 1.188333). Di sisi lain, Facebook *Prophet* tidak berkinerja baik (RMSE keseluruhan sebesar 6.9666).

Kelebihan penelitian ini adalah ketersediaan dataset dengan *volume* besar dan rentang waktu yang luas, sehingga memungkinkan identifikasi tren dan musiman dengan jelas. Selain itu, pemilihan model peramalan yang sesuai dengan jenis data yang ada dalam dataset dapat meningkatkan akurasi peramalan. Kekurangan dari penelitian ini adalah pembatasan pada penggunaan hanya 100 produk per kategori tanpa memberikan penjelasan mengenai kriteria pemilihan produk tersebut.

Mengambil kesimpulan dari penelitian diatas, penggunaan metode ARIMA akan diterapkan dalam tugas akhir ini. Keputusan ini didasarkan pada karakteristik data historis yang panjang serta hasil yang memuaskan dari penelitian sebelumnya. Tidak hanya itu, dalam tugas akhir ini juga akan disertakan klasifikasi untuk mengidentifikasi kategori-kategori produk yang nantinya akan digunakan untuk memberi label pada produk. Hal ini akan mempermudah proses peramalan di masa depan berdasarkan kategori.

#### **2.2.4. *Predictive Analytics for Demand Forecasting – A Comparison of SARIMA and LSTM in Retail SCM (Falatouri et al., 2022)***

Penelitian ini membahas masalah penting dalam bisnis makanan di Austria, yaitu kesulitan dalam meramalkan penjualan produk mudah rusak, seperti buah dan sayuran segar. Mengingat produk yang dijual mudah rusak, apabila toko menstok terlalu banyak dan produk tidak terjual, maka akan mengakibatkan pemborosan biaya. Di sisi lain, jika produk terlalu sedikit, toko akan kehilangan pelanggan.

Penelitian ini menggunakan dataset dari pedagang Austria yang mencakup empat produk buah dan sayuran segar. Dua metode yang digunakan adalah Seasonal Autoregressive Integrated Moving Average (SARIMA) dan *Long Short-Term Memory* (LSTM). Hasil penelitian tergantung pada karakteristik dataset. Jika datasetnya stabil secara historis, LSTM lebih baik. Namun, jika dataset memiliki perilaku musiman, SARIMA lebih cocok. Selain itu, peneliti menggunakan metode *Seasonal Autoregressive Integrated Moving Average with exogenous*

*factors* (SARIMAX) yang mempertimbangkan faktor eksternal seperti promosi. SARIMAX memberikan hasil yang baik, tetapi perlu memperhatikan faktor eksternal yang mempengaruhi prediksi. Uji akurasi menggunakan RMSE dan MAPE.

Kelebihan dari penelitian ini adalah berhasil menemukan metode yang cocok sesuai dengan produk yang dimiliki dan dapat menjelaskan mengapa metode itu cocok untuk produk tersebut. Dari kesimpulan penelitian ini, metode SARIMA akan diterapkan dalam tugas akhir ini untuk mengatasi kekurangan metode ARIMA dalam mengatasi data yang memiliki seasonality.

#### **2.2.5. *Predictive Analytics for Demand Forecasting – A Comparison of SARIMA and LSTM in Retail SCM (Falatouri et al., 2022)***

Dalam penelitian ini, terdapat kendala pada pembukuan manual yang kompleks. Masalah tersebut mencakup kesalahan perhitungan barang masuk, keluar, dan transaksi, serta keterlambatan dalam proses pencatatan dan pembuatan laporan. Sistem manual yang terbatas tidak mampu secara otomatis mengelola stok, menentukan pemesanan kembali, dan memenuhi kebutuhan pelanggan dengan tepat. Oleh karena itu, diperlukan sistem informasi yang efisien untuk memperbaiki pengelolaan data, mempercepat transaksi, dan meningkatkan akurasi laporan.

Solusi yang ditawarkan adalah menerapkan sistem *point of sale* (POS) untuk menggantikan pembukuan manual, dengan metode *Economic Order Quantity* (EOQ) dan *Reorder Point* (ROP) untuk meningkatkan akurasi pengelolaan data persediaan barang. Dengan penggunaan metode ini, kuantitas pemesanan dapat diatur secara optimal, dan notifikasi peringatan dari ROP mencegah kelalaian dalam manajemen persediaan. Hasil penelitian menunjukkan bahwa penerapan POS dengan EOQ dan ROP mencapai tingkat penerimaan 90%, berhasil mengatasi permasalahan, dan membantu meminimalisir biaya operasional serta mengoptimalkan persediaan barang.

Kelebihan penelitian ini terletak pada penerapan sistem *point of sale* (POS) dengan metode *Economic Order Quantity* (EOQ) dan *Reorder Point* (ROP), yang berhasil meningkatkan efisiensi pengelolaan data, meminimalisir biaya operasional, dan mencapai tingkat penerimaan sebesar 90%. Namun, kelemahan dari penelitian ini adalah ketiadaan sistem otomatis yang dapat memicu pemesanan ulang saat stok barang mencapai nilai *reorder point* (ROP).

### 2.3. Tabel State of Art

Tabel 2.1

Tabel State of Art

| Nama Peneliti                                            | Tahun | Masalah                                                                                                                          | Metode    | Hasil                                                                                                                                                                                       |
|----------------------------------------------------------|-------|----------------------------------------------------------------------------------------------------------------------------------|-----------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Muhammad Fauzi                                           | 2009  | Kesulitan meramalkan permintaan produk SKT disebabkan oleh ketergantungan pada pesanan.                                          | SMA, ETS  | <i>Exponential Smoothing</i> dengan $\alpha = 0.1$ adalah metode yang paling baik                                                                                                           |
| Virgin Wineka Nirmala, Dikdik Harjadi dan Robi Awaluddin | 2021  | Fluktuasi dalam penjualan produk<br><br>Penumpukan stok produk<br><br>Dampak pandemi COVID-19 pada permintaan dan pasokan produk | ETS, TMLS | <i>Exponential Smoothing</i> dengan $\alpha = 0.9$ adalah metode yang paling baik<br><br><i>Trend Model Least Square</i> lebih baik daripada <i>Exponential Smoothing Alpha</i> 0,1 dan 0,5 |

|                                                                               |      |                                                                                                                                                                                                                                  |                          |                                                                                                                                                                                                               |
|-------------------------------------------------------------------------------|------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Md Rashidul Hasan, Muntasir A Kabir, Rezoan A Shuvro, dan Pankaz Das          | 2022 | <p>kesulitan meramalkan penjualan produk dikarenakan tren penjualan fluktuatif dan bergantung pada faktor musiman.</p> <p>Volume data yang besar dan beragam memerlukan identifikasi metode yang sesuai untuk setiap produk.</p> | ARIMA, Prophet, LightGBM | <p>ARIMA memiliki RMSE terendah 1.098577</p> <p>LightGBM memiliki RMSE yang hampir sama dengan ARIMA 1.188333</p> <p>Prophet memiliki hasil yang buruk dengan RMSE keseluruhan sebesar 6.9666.</p>            |
| Taha Falatouria, Farzaneh Darbaniana, Patrick Brandtnera dan Chibuzor Udokwua | 2022 | Produk mudah rusak membuat perlunya dilakukan peramalan untuk menghindari pemborosan stok.                                                                                                                                       | LSTM, SARIMA, SARIMA     | <p>LSTM lebih baik untuk dataset yang stabil secara historis</p> <p>SARIMA lebih cocok untuk dataset dengan perilaku musiman</p> <p>SARIMAX memberikan hasil yang baik, tetapi memerlukan faktor external</p> |

|                                                          |      |                                                                         |                        |                   |
|----------------------------------------------------------|------|-------------------------------------------------------------------------|------------------------|-------------------|
| Raffa<br>Ismunandar,<br>Ade Andri<br>Hendriadi,<br>Garno | 2018 | Pembukuan manual yang kompleks yang membuat kesalahan dan keterlambatan | POS dengan EOQ dan ROP | 90% lebih efisien |
|----------------------------------------------------------|------|-------------------------------------------------------------------------|------------------------|-------------------|