

BAB II

KAJIAN LITERATUR

2.1 Industri Mobil Listrik

Industri mobil listrik merupakan sektor industri yang berkembang dengan pesat yang fokus pada pengembangan, produksi dan pemasaran kendaraan bertenaga listrik. Mobil listrik menggunakan motor listrik atau kombinasi motor listrik dan mesin pembangkit daya internal sebagai sumber tenaga, menggantikan mesin pembakaran internal yang menggunakan bahan bakar fosil [8].

Menurut laporan "*Global Electric Vehicle Outlook 2020: Trends and Developments in Electric Vehicle Market*" yang diterbitkan oleh *International Energy Agency (IEA)*. Setelah satu dekade pertumbuhan yang pesat, pada tahun 2020, stok mobil listrik global mencapai angka 10 juta, meningkat 43% dibandingkan tahun 2019, dan mewakili 1% pangsa pasar. *Battery Electric Vehicle (BEV)* menyumbang dua pertiga dari pendaftaran mobil listrik baru dan dua pertiga dari stok pada tahun 2020. Banyak faktor yang berkontribusi terhadap peningkatan pendaftaran mobil listrik pada tahun 2020. Terutama, mobil listrik secara bertahap menjadi lebih kompetitif di beberapa negara berdasarkan total biaya kepemilikan. Beberapa pemerintah memberikan atau memperpanjang insentif fiskal yang melindungi pembelian mobil listrik dari penurunan pasar mobil [9].

2.2. Peramalan

Peramalan/prediksi adalah memperkirakan informasi masa depan menggunakan data masa lalu. Prediksi memainkan peran penting dalam berbagai bidang kehidupan, salah satunya adalah perencanaan untuk memprediksi kondisi masa depan. Fungsi lain dari prediksi adalah sebagai acuan dalam proses pengambilan keputusan. Salah satu ciri keputusan yang baik adalah berdasarkan pertimbangan terhadap sesuatu yang telah terjadi. Masa depan tidak pasti, jadi prediksi tidak pernah 100% akurat. Namun, metode penggunaan dan *hyperparameter* yang sesuai dapat mengubah prediksi tingkat kesalahan yang rendah menjadi perkiraan yang baik [10].

Menurut [11] peramalan dibagi berdasarkan waktu, waktu terbagi atas 3 kategori yaitu :

1. Peramalan jangka pendek dimana peramalan ini mencakup jangnan waktu hingga 1 tahun tetapi umumnya kurang dari 3 bulan. Peramalan jangka pendek digunakan antara lain :

untuk merencanakan tingkat produksi, pembelian, penjadwalan kerja, dan jumlah tenaga kerja.

2. Peramalan jangka menengah yang pada umumnya mencakup hitungan bulanan hingga 3 tahun. Peramalan jangka menengah ini biasa digunakan untuk perencanaan penjualan, perencanaan dan anggaran produksi, anggaran kas, dan menganalisis bermacam-macam rencana operasi.
3. Peramalan jangka panjang yang umumnya untuk perencanaan masa 3 tahun atau lebih. Peramalan jangka panjang biasanya digunakan untuk merencanakan produk baru, pembelanjaan.

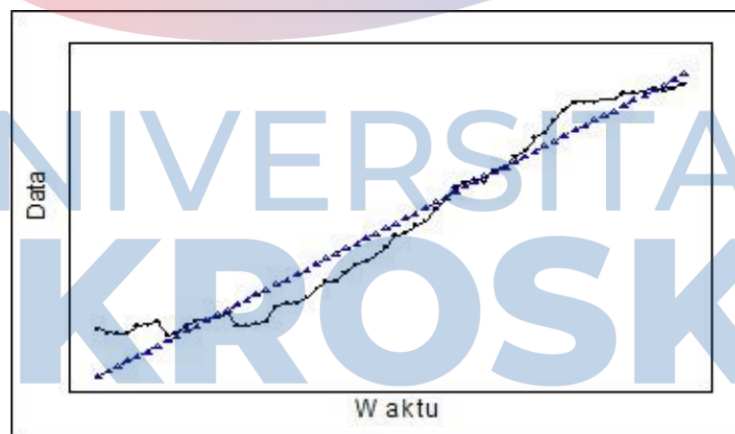
2.3 Data Time Series

Data runtun waktu (*time series*) adalah jenis data yang dikumpulkan menurut urutan waktu dalam suatu rentang waktu tertentu (jam, hari, minggu, bulan, triwulan, atau tahun) [12].

Dikutip dari [13] ada 4 tipe pola data runtun waktu, yaitu :

1. Pola Data *Trend*


Pola ini terjadi bila ada kenaikan atau penurunan dari data secara gradual dari gerakan datanya dalam kurun waktu panjang.



Gambar 2.1 Pola Data *Trend*

2. Pola Data *Seasonality*


Pola *seasonality* atau musiman terjadi bila pola datanya berulang sesudah sesuatu periode waktu tertentu. Periode ini bisa berupa hari, minggu, bulan, triwulan, dan tahun.



Gambar 2.2 Pola Data *Seasonality*

3. Pola Data *Cycles*

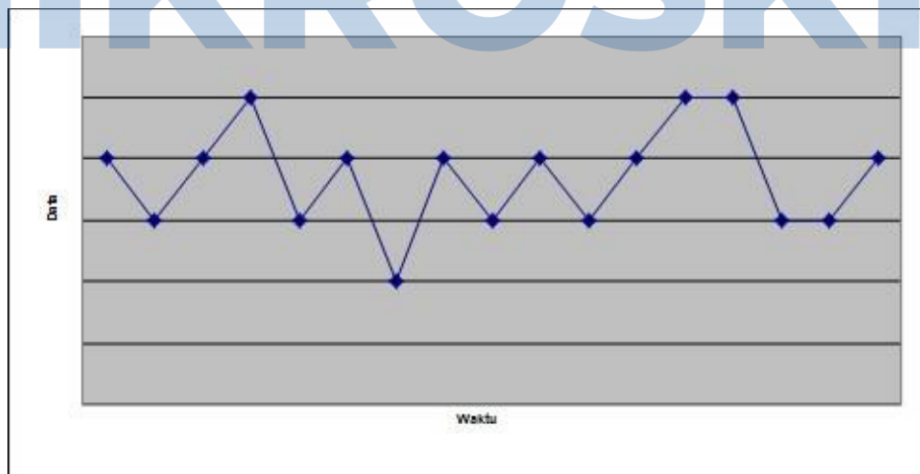
Pola *cycles* atau siklus terjadi ketika fluktuasi data yang diberikan tidak tetap dan pergerakan data tidak teratur.



Gambar 2.3 Pola Data *Cycles*

4. Pola Data *Horizontal*

Pola *horizontal* atau stasioner terjadi bila nilai data berfluktuasi di sekitar nilai rata-rata yang tetap stabil atau disebut stasioner terhadap nilai rata-ratanya.



Gambar 2.4 Pola Data *Horizontal*

2.4 Analisis *Time Series*

Runtun waktu merupakan kumpulan objek atau data observasi yang berurutan berdasarkan waktu. Metode deret waktu merupakan metode yang menganalisa hubungan antara variabel yang akan diprediksi dengan variabel waktu. Data runtun waktu (*Time Series*) merupakan jenis data berupa variabel yang sudah terurut dalam rentang waktu tertentu, misalnya harian, mingguan, bulanan, triwulan, dan tahunan [14].

Time series adalah himpunan observasi terurut dalam waktu atau dalam dimensi lain. Waktu antara dua observasi yang berurutan biasanya adalah konstan atau tidak dapat dilakukan akumulasi terhadap observasi untuk suatu periode waktu yang digunakan tidak benar-benar konstan misalnya bulan kalender. Menurut sejarah nilai observasinya, *Time Series* dibedakan menjadi dua yaitu deterministik dan stokastik. Deterministik adalah suatu runtun waktu dimana keadaan yang akan datang dapat diramalakan secara pasti dan tidak perlu diselidiki kembali. Stokastik adalah suatu runtun waktu dimana keadaan yang akan datang bersifat probabilistik menurut observasi di masa lampau [15].

2.4.1 Analisis Trend

Trend adalah suatu gerakan (kecenderungan) naik atau turun dalam jangka panjang, yang diperoleh dari rata-rata perubahan dari waktu ke waktu. Rata-rata perubahan tersebut bisa bertambah bisa berkurang. Jika rata-rata perubahan bertambah disebut *trend* positif atau *trend* mempunyai kecenderungan naik. Sebaliknya, jika rata-rata perubahan berkurang disebut *trend* negatif atau *trend* yang mempunyai kecenderungan menurun. Garis *trend* pada dasarnya garis regresi dan variabel bebas (x) merupakan variabel waktu. Tren garis lurus (*linier*) adalah suatu *trend* yang diramalkan naik atau turun secara garis lurus. Variabel waktu sebagai variabel bebas dapat menggunakan waktu tahunan, semesteran, bulanan, atau mingguan. Analisis tren garis lurus (*linier*) terdiri atas metode kuadrat kecil atau (*least square*) dan moment. *Trend* menunjukkan perubahan nilai suatu variabel yang *relative* stabil perubahan populasi, perubahan harga, perubahan teknologi, dan peningkatan produktivitas [6].

2.4.2 Analisis Musiman

Apabila *trend* berhubungan dengan jangka menengah dan panjang, maka variasi musiman berhubungan dengan perubahan atau fluktuasi dalam musim-musim tertentu atau

tahunan. Variasi musiman menjelaskan fluktuasi dalam satuan bulanan atau triwulan atau semester dalam satu tahun. Salah satu komponen yang mempengaruhi data *time series* adalah komponen musiman. Gerakan musiman (*seasonal movement*) merupakan gerakan yang teratur artinya naik turunnya terjadi pada waktu-waktu yang sama. Disebut gerakan musiman oleh karena terjadinya bertepatan dengan pergantian musim didalam satu tahun atau dalam waktu yang singkat [6].

2.5 Prophet

Prophet merupakan metode peramalan yang dikembangkan Facebook dengan tujuan untuk menangani masalah di platform mereka yang sekarang berubah menjadi *meta*. Model peramalan *Prophet* mengkombinasikan model *linier* dan *non linier* dalam melakukan *forecasting* dengan mengidentifikasi *trend*, musiman dan efek liburan (jika perlu). Komponen *trend* didefinisikan sebagai fungsi logistik pertumbuhan, sedangkan musiman ditangkap oleh model *Fourier* yang diadaptasi. Model *Prophet* juga dapat menghitung efek hari libur atau *outlier* yang ditandai oleh data yang jauh dari tren umum [16]. Model *Prophet* dapat ditulis dengan persamaan (1) berikut [17] :

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \quad (1)$$

$g(t)$ adalah fungsi tren dimana model non-periodik merubah nilai dari deret waktu. $s(t)$ mewakili perubahan periodik (semisal nya musiman mingguan dan tahunan), dan $h(t)$ mewakili dampak dari hari libur yang terjadi pada jadwal tidak beraturan yang potensial pada satu atau lebih hari. ϵ_t mewakili perubahan istimewa yang tidak diakomodasi oleh model yang diasumsikan bahwa terdistribusi secara normal.

Ada dua model tren yang didukung oleh *Prophet* yaitu pertumbuhan jenuh (*saturating growth*) dan *linier* sepotong-sepotong (*piecewise linear*) dengan persamaan (2) berikut :

$$g(t) = \frac{C}{1 + \exp(-k(t - m))} \quad (2)$$

dengan C sebagai kapasitas pembawa (*carrying capacity*), k sebagai tingkat pertumbuhan (*growth rate*) dan m sebagai parameter penyeimbang (*offset*). Kemudian *linier* sepotong-sepotong dimodelkan dengan persamaan (3) berikut :

$$g(t) = \frac{C_t}{1 + \exp(-(k + a(t)\delta)(t - (m + a(t)\gamma)))} \quad (3)$$

dengan k sebagai tingkat pertumbuhan (*growth rate*), δ sebagai penyesuaian (*adjustments*), dan m sebagai parameter penyeimbang.

Model musiman yang didukung oleh *prophet* menggunakan deret *Fourier* untuk fleksibilitas dengan persamaan (4) berikut :

$$s(t) = \sum_{n=1}^N (a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \left(\frac{2\pi nt}{P}\right)) \quad (4)$$

dengan P sebagai periode deret waktu, komponen musiman ditunjukkan dengan persamaan (5) berikut :

$$s(t) = X(t)\beta \quad (5)$$

Model hari libur yang didukung oleh *prophet* menggunakan persamaan (6) berikut :

$$h(t) = [1(t \in D_1), \dots, 1(t \in D_L)] \quad (6)$$

Prophet menggunakan model deret waktu yang mudah digunakan terdiri dari tiga komponen utama yaitu tren, musim, dan hari libur. Fungsi tren yaitu memodelkan perubahan non-periodik dalam deret waktu. Fungsi musim yaitu mewakili perubahan periodik (misalnya harian, mingguan, bulanan, dan tahunan). Fungsi libur yaitu mempresentasikan efek liburan yang terjadi pada jadwal yang tidak teratur selama satu atau beberapa hari [7]. Model ini berfungsi paling baik dengan deret waktu yang memiliki efek tren seperti penjualan Tesla selain itu *prophet* sangat kuat dalam menangani data yang hilang, pergeseran tren dan menangani data yang menyimpang terlalu jauh dari rangkaian data lainnya (*outliers*) dengan baik.

2.6 Holt-Winters

Metode *Holt-Winters* juga disebut metode pemulusan eksponensial dengan cara melakukan pendekatan. Metode ini dapat dibagi menjadi dua bagian yakni [18]:

1. Metode Perkalian Musiman (*Multiplicative Seasonal Method*) digunakan untuk variasi data musiman yang mengalami peningkatan/penurunan (fluktuasi).
2. Metode Penambahan Musiman (*Additive Seasonal Method*) digunakan untuk variasi musiman yang bersifat konstan.

Metode *Holt-Winters* didasarkan pada tiga persamaan pemulusan, yakni persamaan pemulusan keseluruhan (α), pemulusan tren (β), dan persamaan pemulusan musiman (γ). Adapun langkah-langkahnya sebagai berikut [19]:

1. Pemulusan *eksponensial* (level) dengan menggunakan persamaan (7) untuk model multiplikatif dan persamaan (8) untuk model aditif.

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (7)$$

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (8)$$

Dimana,

- L_t = Level pada tahun ke - t
- L_{t-1} = Level pada tahun ke - $t - 1$
- b_{t-1} = *Trend* pada tahun ke - $t - 1$
- Y_t = Data aktual ke - t
- α = Konstanta pembobotan level ($0 < \alpha < 1$)
- S_t = *Seasonal* pada tahun ke - t
- s = Panjang musiman ($s = 12$)

2. Pemulusan unsur kecenderungan (*trend*) dengan menggunakan persamaan (9) baik untuk model *multiplikatif* maupun model *aditif*.

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}(L_{t-1} + b_{t-1}) \quad (9)$$

Dimana,

- b_t = *Trend* pada tahun ke - t
- L_t = Level pada tahun ke - t
- L_{t-1} = Level pada tahun ke - $t - 1$
- b_{t-1} = *Trend* pada tahun ke - $t - 1$
- β = Konstanta pembobotan *trend* ($0 < \beta < 1$)
- t = Periode musiman

3. Pemulusan musiman dengan menggunakan persamaan (10) untuk model *multiplikatif* dan persamaan (11) untuk model *aditif*.

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (10)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (11)$$

Dimana,

- S_t = *Seasonal* pada tahun ke - t
- Y_t = Data aktual pada tahun ke - t
- L_t = Pemulusan Eksponensial pada tahun ke - t
- γ = Konstanta pembobotan *seasonal* ($0 < \beta < 1$)
- S_{t-s} = Pemulusan faktor musiman
- t = Periode musiman
- s = Panjang musiman ($s = 12$)

4. Peramalan (*forecasting*) didapatkan dengan persamaan (12) untuk model *multiplikatif* dan persamaan (13) untuk model *aditif*.

$$F_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (12)$$

$$F_{t+m} = L_t + b_t m + S_{t-s+m} \quad (13)$$

Dimana,

F_{t+m} = Hasil Peramalan ke - $t + m$

L_t = Pemulusan Eksponensial pada tahun ke - t

S_{t-s} = Pemulusan faktor musiman


t = Periode musiman

s = Panjang musiman ($s = 12$)

m = Periode waktu yang akan diramalkan

2.7 OSEM N Framework

Obtain Scrub Explore Model Interpretasi (OSEMN) merupakan tahapan-tahapan atau urutan aktivitas yang jelas dan menjadi hal penting dalam sebuah proses data *science* yang bermanfaat untuk pemecahan masalah dalam bidang analisis data *science* [20]. Tahapan data *science* dibagi menjadi lima *stage* seperti yang ditunjukkan pada gambar 2.1 berikut.



Gambar 2.5 *Obtain Scrub Explore Model Interpretasi* (OSEMN)

2.7.1 *Obtain / Data Collection*

Langkah pertama yang dikerjakan pada *framework* OSEM N adalah mengumpulkan data yang diperoleh dari sumber yang tersedia dengan berbagai macam format. Data yang digunakan pada proses data *science* harus menggunakan data yang dapat digunakan untuk analisis data [21].

2.7.2 *Srub*

Aktivitas berikutnya dalam kerangka kerja ini adalah melakukan *scrubbing* data yang merupakan proses *preprocessing* dataset dengan cermat sebelum dioperasikan. Dataset dan variabel-variabelnya terutama akan dibersihkan, disaring, diganti, digabungkan, dihilangkan, dan diekstraksi [22].

2.7.3 *Explore*

Explore data adalah tahapan untuk mencari informasi dari kumpulan data yang akan digunakan pada proses pemodelan dan dapat digunakan untuk membantu proses pembuatan hipotesis. Pada tahap eksplorasi data, hal yang perlu dilakukan adalah memahami data seperti memeriksa data dan propertinya agar dapat menemukan pola dan tren dalam penggunaannya [23].

2.7.4 **Model**

Pemodelan data dilakukan dengan menentukan model yang akan digunakan dalam melakukan prediksi di komputer. Secara umum, pemodelan yang dimaksud adalah membuat deskripsi abstrak mengenai bentuk model prediksi apa yang ingin digunakan dalam analisis data dari dataset yang dimiliki [24]. Selain itu proses ini juga dilakukan dengan melatih model untuk dapat memprediksi dan meramalkan data di masa depan.

2.7.5 *Interpret*

Interpretasi hasil penelitian penting untuk memahami efektivitas penelitian. Ini perlu untuk mendeskripsikan hasil secara jelas dengan cara yang dapat dibandingkan dengan peneliti lain. Hasil harus diinterpretasikan secara objektif dan kritis sebelum menilai implikasinya dan menarik kesimpulan, Ini adalah fase terpenting namun tidak teknis karena berkaitan dengan memahami data dengan memahami cara menyederhanakan dan meringkas hasil dari semua model yang telah dibangun. Ini memerlukan penarikan kesimpulan yang berarti dan rasionalisasi wawasan yang dapat ditindaklanjuti yang pada dasarnya memungkinkan kita untuk mencari tahu apa tindakan selanjutnya [25].

2.8 **Evaluasi Model**

Suatu prediksi dikatakan sempurna jika nilai prediksi variabelnya sesuai dengan nilai sebenarnya. Sangat sulit, bahkan mungkin mustahil, untuk selalu membuat prediksi yang

benar. Oleh karena itu, diharapkan prediksi dapat dilakukan dengan kesalahan yang minimal. Kesalahan prediksi tidak hanya disebabkan oleh kesalahan dalam pemilihan metode, tetapi juga dapat disebabkan oleh jumlah data observasi yang terlalu kecil untuk menggambarkan perilaku/pola sebenarnya dari variabel yang bersangkutan [26].

Ada beberapa cara dalam menghitung nilai kesalahan diantaranya [27] :

a) *Mean Absolute Error (MAE)*

MAE atau simpangan rata-rata mutlak mencari akurasi peramalan dengan cara meratakan nilai absolut kesalahan peramalan. Nilai kesalahan diukur dari data yang sama seperti pada data aslinya. Nilai MAE dapat dihitung dengan menggunakan persamaan (14) berikut :

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (14)$$

Dimana :

n = jumlah data

y_i = nilai actual

\hat{y}_i = nilai prediksi

b) *Mean Square Error (MSE)*

Metode mencari nilai kesalahan MSE merupakan metode yang hampir sama dengan metode MAE, perbedaannya ialah nilai kesalahan pada MSE dikuadratkan. Nilai MSE yang rendah atau mendekati nol menunjukkan bahwa hasil ramalan konsisten dengan data actual dan dapat digunakan untuk menghitung ramalan di periode waktu mendatang. Nilai MSE dapat dihitung dengan menggunakan persamaan (15) berikut :

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (15)$$

Dimana :

n = jumlah data

y_i = nilai actual

\hat{y}_i = nilai prediksi

c) *Mean Absolute Percentage Error (MAPE)*

Persentase nilai kesalahan rata-rata mutlak atau MAPE adalah metode yang menunjukkan seberapa besar nilai kesalahan dibandingkan dengan nilai data aslinya. Jika nilai kesalahan MAPE yang diperoleh dibawah 10% berarti model data memiliki kinerja yang sangat baik. Secara matematis, MAPE menggunakan dapat dihitung dengan persamaan (16) berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - \hat{Y}_t}{X_t} \right| * 100\% \quad (16)$$

Dimana,

n = banyaknya data yang diamati,

X_t = Data pada periode t ,

\hat{Y}_t = Peramalan pada periode t .

Tingkat efisiensi hasil peramalan berdasarkan metode MAPE dikelompokkan kedalam rentang signifikansi tertentu yang menunjukkan seberapa baik hasil peramalan. Rentang hasil tersebut dapat dilihat pada Tabel 2.1 [35].

Tabel 2.1 Tingkat Signifikansi Metode MAPE

Persentase MAPE	Tingkat Signifikansi
<10%	<i>Excelent</i> (hasil peramalan sangat baik)
10-20%	<i>Good</i> (Hasil peramalan baik)
20-50%	<i>Reasonable</i> (hasil peramalan cukup)
>50%	<i>Bad</i> (hasil peramalan buruk)

2.9 Penelitian Terdahulu

Adapun dalam pengerjaan skripsi ini, memiliki beberapa studi literatur yang diambil sebagai refrensi dalam pengerjaannya. Beberapa studi literatur yang diambil dapat dilihat pada tabel 2.2.

Tabel 2.2 Studi Literatur Terdahulu

No	Nama Peneliti	Model	Kontribusi	Area Aplikasi	Hasil
1	Dienda Rizkya Hayuningtyas Roosaputri, Chritine Dewi [28]	<i>Prophet</i> , ARIMA, dan LSTM	Melakukan peramalan penjualan tiket wisata taman hiburan dengan periode Januari 2020 – April 2023	Pariwisata	<i>Prophet</i> memiliki nilai MAE 546.523, ARIMA memiliki nilai MAE 478.887, dan LSTM memiliki nilai MAE 695.374
2	Yudha Alif Auliya, Yanuar, Nurdiansyah, Ari Puji Astuti [29]	<i>Prophet</i>	Melakukan peramalan jumlah pengunjung objek wisata dengan menggunakan data periode Januari 2012 – Desember 2021	Pariwisata	<i>Prophet</i> memiliki nilai MAPE 9.758%
3	Fristiani Theresia Br Sitepu, Vince Amelia Prada Sirait, Roni Yunis [25]	<i>Prophet</i>	Melakukan peramalan jumlah mahasiswa baru dengan menggunakan dataset mahasiswa baru T.A 2010/2011 sampai T.A 2019/2020	Ekonomi	<i>Prophet</i> memiliki nilai MAPE 0.04327568%
4	Anis Zubair, Rauda Umamit[30]	<i>Holt-Winters</i>	Melakukan peramalan penjualan pada industri makanan ringan dengan periode Januari 2016 – Desember 2020	Ekonomi	<i>Holt-Winters</i> memiliki nilai MAPE 8%

5	Bagas Wahyu Nur Tanya, Daniel Swanjaya [31]	<i>Holt-Winters</i> dan <i>Backpropagation</i>	Melakukan peramalan penjualan dengan data harian Oktober 2020	Ekonomi	<i>Holt-Winters</i> memiliki nilai MAD 1.7963 dan <i>Backpropagation</i> memiliki nilai MAD 0.00057201
6	Muhammad Ary Praasetyo, Umi Mahdiyah, Daniel Swanjaya [32]	<i>Holt-Winters Additive</i> dan <i>Holt-Winters Multiplicative</i>	Melakukan peramalan harga saham PT Prodi Widyahusada periode Desember 2016 – Juni 2023	Saham	<i>Holt-Winters Additive</i> memiliki nilai MAPE 1.81% dan <i>Holt-Winters Multiplicative</i> memiliki nilai MAPE 2.06%

UNIVERSITAS MIKROSKIL