

BAB 2

LANDASAN TEORI

2.1 Emisi Karbon

2.1.1 Pengertian Emisi Karbon

Emisi karbon merupakan sebuah proses pelepasan gas karbon dioksida (CO_2) ke atmosfer, yang merupakan kontributor utama terhadap terjadinya pemanasan global serta perubahan iklim. Salah satu penyebab emisi karbon adalah aktivitas operasional perusahaan [18]. Emisi karbon dapat dihasilkan dari berbagai sumber, seperti hasil yang ditimbulkan dari pembakaran bahan bakar fosil, produksi industri, dan proses alamiah seperti pernapasan tumbuhan dan hewan [19].

Pelepasan gas CO_2 memberikan dampak buruk serta resiko yang ditimbulkan yang dapat dipecah menjadi dua antara lain:


1. Resiko Jangka Pendek

Peningkatan kemiskinan, ketahanan pangan, kesehatan, dan ekosistem yang memburuk serta ancaman besar terhadap keanekaragaman hayati dan sumber daya air dan laut adalah risiko jangka pendek yang akan dihadapi manusia [20].

2. Resiko Jangka Menengah hingga Panjang

Berbagai simulasi menunjukkan bahwa risiko yang dihadapi ekosistem alam akan sangat parah dalam jangka panjang. Keanekaragaman hayati akan berkurang dan bahkan bisa punah jika ekosistem terusak [20].

Negara-negara dengan tingkat penghasil karbon tertinggi di dunia termasuk Amerika Serikat, Rusia, India, Uni Eropa, dan Jepang [21]. Emisi karbon memengaruhi perubahan iklim dan berpotensi menyebabkan pemanasan global dan perubahan iklim [20].



Gambar 2.1. Emisi CO₂ dari bahan bakar fosil dan perubahan penggunaan lahan dunia.

Sumber: ourworldindata.org, 2023 [22]

Gambar 2.1, merupakan grafik yang diperoleh dari lembaga *Our World in Data* yang memberikan gambaran terhadap peningkatan emisi karbon global yang mencapai total 41.46 juta ton. Data ini mencakup emisi CO₂ dari segala sumber energi yang ada, seperti gas, minyak, dan batu bara, serta proses industri, seperti pembakaran gas dan produksi semen. Selain itu, dampak dari penggunaan lahan dan perubahan penggunaan lahan turut berkontribusi pada peningkatan emisi CO₂, terutama di negara-negara yang memiliki sektor pertanian yang luas atau di mana pembebasan lahan adalah masalah yang serius [22].

2.1.2 Carbon Trading

Carbon trading merupakan sebuah upaya untuk mendukung pengurangan emisi karbon dan pemanasan global, *carbon trading* adalah sebuah mekanisme berbasis pasar [23]. Dalam proses ini, setiap *unit* kredit karbon yang menunjukkan penurunan atau penyerapan emisi karbon dioksida diperdagangkan ke dalam kerangka kerja yang telah ditetapkan sebelumnya. Sehingga upaya ini tidak hanya dapat menghasilkan banyak keuntungan ekonomi, tetapi juga dapat membantu

dalam mengurangi emisi karbon dioksida secara signifikan.

Perdagangan karbon juga dapat membantu sektor industri mencapai tujuan pengurangan intensitas karbon. Kegiatan jual beli kredit karbon pasti akan menarik minat pasar, terutama dari pihak-pihak yang menghasilkan emisi karbon yang tinggi. Ini memiliki potensi untuk mendorong penggunaan teknologi yang lebih ramah lingkungan dan investasi dalam proyek yang menghasilkan emisi karbon yang rendah. Pembeli dan penjual kredit karbon berada di tempat yang sama di pasar perdagangan karbon. Pihak yang bertanggung jawab atas pelaksanaan pasar menjalankan pengawasan pasar secara terpisah, dengan otoritas untuk melakukan inspeksi dan penegakan hukum [24].

Sesuai dengan ERPA (*Emission Reduction Purchase Agreement*), perdagangan karbon merupakan salah satu upaya yang efektif dalam mengurangi emisi karbon, memberikan kontribusi dalam mitigasi pemanasan global, dan menjadi inisiatif untuk mengurangi dampak pemanasan global [23].

2.1.3 Sumber Tenaga Listrik

Energi listrik merupakan suatu bentuk aliran muatan listrik yang utamanya terdiri dari elektron yang bergerak melalui konduktor seperti kawat. Listrik merupakan komponen yang penting dalam kehidupan saat ini untuk berbagai kebutuhan, energi listrik dapat dihasilkan melalui berbagai sumber energi primer seperti pada bahan bakar fosil seperti batu bara dan gas alam, serta sumber energi terbarukan seperti tenaga angin, tenaga surya, dan tenaga air. Proses pembangkitan listrik biasanya dilakukan melalui pembangkit listrik, di mana energi primer dikonversi menjadi energi listrik melalui mekanisme seperti generator [25].

Berikut ini merupakan beberapa sumber energi pembangkit listrik dengan menggunakan energi primer sebagai sumbernya.

- **Batu Bara:** Batu bara merupakan sumber utama pembangkit listrik. Pembakarannya menghasilkan energi termal yang diubah menjadi listrik oleh generator, namun juga menghasilkan emisi (CO_2) yang merusak lingkungan [26].
- **Gas Alam:** Gas alam digunakan untuk pembangkit listrik dengan efisiensi tinggi dan emisi lebih rendah dibanding batu bara, terutama melalui teknologi siklus gabungan [27].

- **Tenaga Air:** Menggunakan aliran air untuk menggerakkan turbin dan menghasilkan listrik, tergantung pada ketersediaan air yang dipengaruhi oleh perubahan iklim dan musim [28].
- **Tenaga Nuklir:** Menghasilkan listrik melalui reaksi nuklir dengan emisi karbon sangat rendah, meskipun ada risiko radiasi dan masalah pengelolaan limbah [29].

Sedangkan berikut merupakan sumber-sumber pembangkit listrik dari energi terbarukan.

- **Tenaga Angin:** Menggunakan turbin angin untuk mengubah energi angin menjadi listrik.
- **Tenaga Surya:** Menggunakan sel surya untuk mengubah energi matahari menjadi listrik.
- **Biomassa:** Menggunakan materi organik untuk menghasilkan energi panas yang dapat dikonversi menjadi listrik.
- **Tenaga Hidro:** Menggunakan aliran air untuk menggerakkan turbin dan menghasilkan listrik.
- **Energi Geotermal:** Menggunakan panas dari dalam bumi untuk menghasilkan energi [30].

2.1.4 Faktor-faktor yang Mempengaruhi Penggunaan Listrik

Terdapat sejumlah variabel yang dapat memengaruhi penggunaan listrik setiap hari, termasuk kebiasaan penggunaan listrik, jumlah penduduk, tingkat ekonomi, dan cuaca. Peningkatan suhu di udara luar juga dapat mempengaruhi penggunaan listrik [31]. Sebagai contoh, pada musim panas, AC dan kipas angin akan digunakan lebih banyak daripada pada musim dingin, dan pemanas ruangan akan digunakan lebih banyak pada musim dingin. Selain itu, kebiasaan sehari-hari Anda yang menggunakan listrik, seperti menggunakan peralatan elektronik dan pencahayaan, dapat memengaruhi jumlah listrik yang digunakan [32].

2.2 *Machine Learning*

Machine learning adalah bidang kecerdasan buatan yang memungkinkan sistem komputer untuk memperoleh pengetahuan dari data tanpa perlu diprogram secara khusus. Hal ini dicapai melalui penggunaan model matematika dan algoritma yang memungkinkan mesin untuk menemukan pola dalam data dan membuat keputusan atau prediksi berdasarkan pola tersebut [33].

Dengan kata lain, mesin belajar secara otomatis mengekstrak informasi dari data yang diberikan dan menggunakan informasi tersebut untuk melakukan tugas-tugas tertentu, seperti membuat prediksi atau mengambil keputusan, tanpa memerlukan instruksi eksplisit dari pengguna. Algoritma *machine learning* digunakan untuk melakukan pembelajaran model. Tipe pembelajaran mesin sendiri terdiri dari 3 jenis yaitu:

1. *Supervised Learning*, *dataset* sudah diberi label untuk digunakan. Metode ini menggunakan kumpulan sampel untuk merangkum karakteristik distribusi dan perilaku dalam berbagai aplikasi, membentuk model perilaku.
2. *Unsupervised Learning*, digunakan untuk menentukan struktur yang tersembunyi dari dataset yang tidak dilabelkan.
3. *Reinforcement Learning*, metode pembelajaran yang tidak memerlukan pengetahuan sebelumnya karena memanfaatkan percobaan atau interaksi terus-menerus dengan lingkungan yang dinamis untuk memperoleh pengetahuan.

2.2.1 *Time Series Forecasting*

Time Series Forecasting termasuk kedalam kategori *supervised learning* yang melibatkan penggunaan dataset yang sudah diberi label untuk melatih model prediktif yang dapat membantu untuk mendapatkan informasi penting dan membuat keputusan. Karena waktu memainkan peran penting dalam model peramalan, model peramalan deret waktu sangat penting karena sangat bergantung pada data yang tersedia. Jika data yang diperlukan tidak tersedia atau tidak relevan, metode peramalan kualitatif harus digunakan. Sebaliknya, apabila data tersebut tersedia serta relevan, maka akan digunakan metode kuantitatif seperti analisis deret waktu.

Time Series Forecasting termasuk dalam kategori *supervised learning*, yang melibatkan penggunaan *dataset* yang telah diberikan label untuk dapat melatih

model prediktif yang dapat membantu dalam mendapatkan informasi penting serta membuat keputusan. Model *time series forecasting* sangat penting karena sangat bergantung pada data yang tersedia karena waktu memainkan peran penting dalam model peramalan.

Komponen utama deret waktu adalah *level* (tingkat), *tren*, *seasonality*, dan *cyclic*. Komponen-komponen tersebut memiliki karakteristik seperti informasi numerik mengenai data historis dan pola serupa yang kemungkinan berulang di masa depan. Dengan memahami dan menganalisis elemen-elemen ini, diharapkan dapat membuat keputusan yang lebih baik di masa depan. [34].

1. *Trend* adalah ketika data deret waktu mengalami fluktuasi baik naik turun pada jangka waktu tertentu.
2. *Seasonality* adalah saat faktor seperti musiman, seperti minggu, bulan, atau tahun mempengaruhi data deret waktu. *Seasonality* terjadi ketika data menunjukkan kenaikan dan penurunan daripada frekuensi tetap.
3. *Cyclic* biasanya disebabkan oleh perubahan alamiah yang tidak terduga dalam suatu fenomena atau proses. Pola perubahan yang berulang secara berkala tetapi tidak memiliki frekuensi tetap biasanya merupakan penyebab siklik.

2.2.2 Facebook Prophet Model

FB Prophet merupakan suatu algoritma prediksi yang dirancang oleh Facebook untuk secara cepat dan mudah memproyeksikan data *time-series*. Model ini menggunakan pendekatan pemodelan statistik yang dikenal sebagai "*additive regression model with non-linear trends*" untuk meramalkan data waktu. Algoritma ini terdiri dari beberapa komponen penting, termasuk elemen-elemen seperti tren yang mencerminkan perubahan jangka panjang dalam data, musiman yang menunjukkan pola berulang dalam data, serta hari libur. Implementasi model ini dapat dilakukan menggunakan bahasa pemrograman Python dan R [35].

Rumus *Facebook Prophet Model* dapat dilihat sebagai berikut:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \quad (2.1)$$

Keterangan:

- $y(t)$ adalah nilai data yang dianalisis atau diprediksi menggunakan model deret waktu tertentu.

- $g(t)$ adalah *trend*, yaitu pola perubahan non-periodik dalam nilai deret waktu.
- $s(t)$ adalah *seasonality*, yang mewakili variasi musiman (tahunan, bulanan, mingguan).
- $h(t)$ adalah *holidays*, menunjukkan dampak hari libur yang mempengaruhi deret waktu dalam satu atau beberapa hari.
- $\varepsilon(t)$ adalah *error term*, yang menunjukkan variasi idiosinkratik yang tidak terakomodasi oleh model.

Facebook Prophet model menggunakan waktu sebagai faktor penjelas (*regressor*) serta melakukan *fitting* data ke model pertumbuhan yang jenuh (*nonlinear*) atau model linier dengan segmen linier (*piecewise linear*) sebagai komponen-komponennya [17]. Berikut merupakan rumus untuk menghitung pertumbuhan logistik / *nonlinear* dapat dilihat pada persamaan 2.2.

$$g(t) = \frac{C}{1 + e^{-k(t-m)}} \quad (2.2)$$

Keterangan:

- C adalah *carrying capacity* (batas maksimum populasi yang dapat ditopang oleh lingkungan).
- k adalah *growth rate* (tingkat pertumbuhan relatif populasi).
- m adalah *parameter offset* (titik tengah di mana pertumbuhan mencapai setengah dari *carrying capacity*).

Dalam penerapannya, *logistic growth model* yang digambarkan adalah kasus khusus dari kurva pertumbuhan logistik umum yang hanya merupakan satu jenis kurva sigmoid yang memungkinkan perluasan yang relatif langsung dari model tren ini ke kelompok kurva lainnya [17]. Sedangkan untuk *piecewise linear model* digambarkan dengan persamaan 2.3.

$$g(t) = (k + a(t))^T \delta (m + a(t)^T \gamma) \quad (2.3)$$

Keterangan:

- k adalah tingkat pertumbuhan.
- δ adalah tingkat penyesuaian.

- m adalah parameter pergeseran.
- T menunjukkan *transpose* dari vektor atau matriks.

Prophet memungkinkan penggunaannya untuk mempertimbangkan efek fluktuasi yang disebabkan oleh hari libur. Pengguna dapat memasukkan data hari libur menggunakan *dataset* bawaan di *library Prophet* atau *dataset custom* [17]. Dalam *Prophet*, komponen musiman menggunakan deret *Fourier* untuk mengidentifikasi pola berulang yang mungkin terjadi setiap hari, setiap minggu, atau setiap tahun. Persamaan untuk komponen musiman adalah:

$$s(t) = \sum_{n=1}^N \left[a_n \cos \left(\frac{2\pi nt}{P} \right) + b_n \sin \left(\frac{2\pi nt}{P} \right) \right] \quad (2.4)$$

Keterangan:

- P adalah periode (misalnya 365,25 untuk tahunan).
- a_n dan b_n adalah koefisien Fourier yang diestimasi.

Efek hari libur menangkap dampak dari hari libur dan acara khusus pada data. Efek ini dimodelkan menggunakan variabel *dummy* untuk hari libur tertentu:

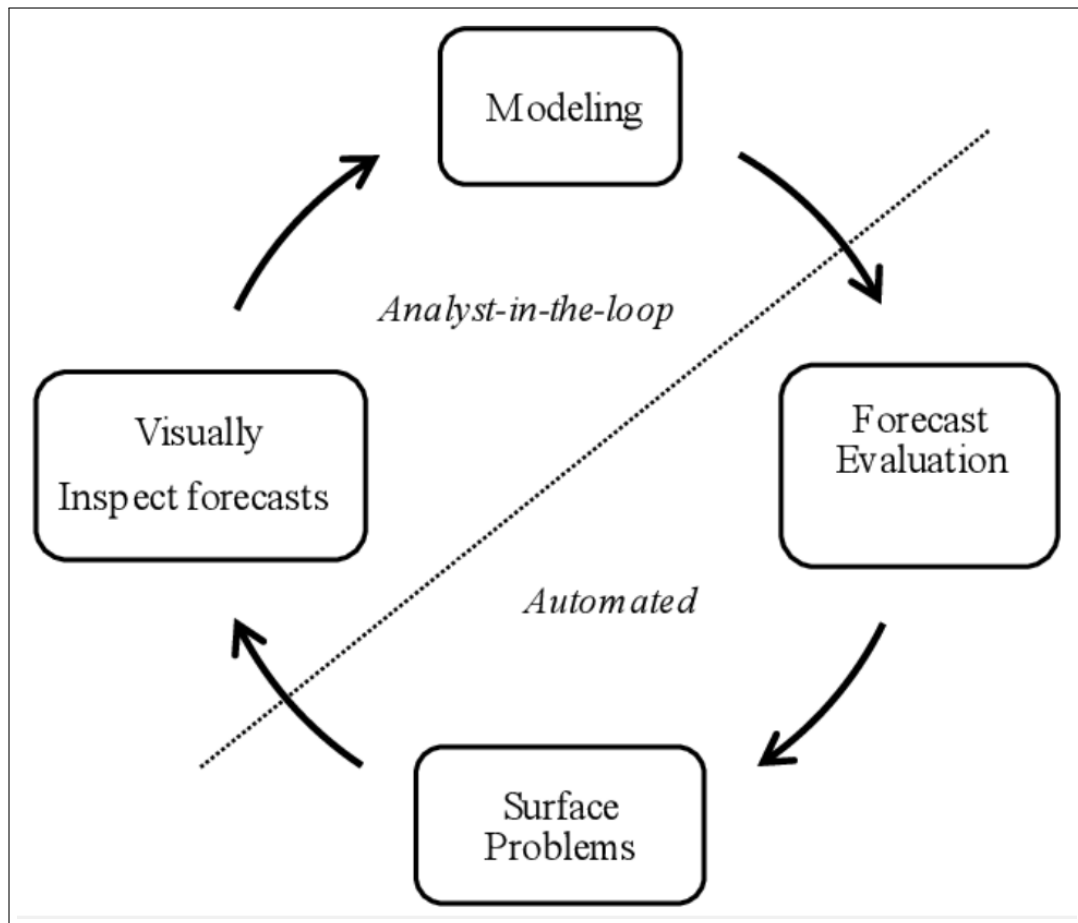
$$h(t) = \sum_{k=1}^N (Z_k 1_{(t \in D_k)}) \quad (2.5)$$

Keterangan:

- Z_k adalah efek liburan pada hari libur k .
- D_k adalah kumpulan hari libur.

Algoritma *FB Prophet* model termasuk kedalam kategori prediksi semi-otomatis, yang penugasannya terbagi menjadi dua antara otomatisasi dan manusia. Gambar 2.2 berikut menunjukkan pembagian tugas dari *FB Prophet* model.

MULTIMEDIA
NUSANTARA



Gambar 2.2. Facebook Prophet Workflow.

Sumber: *Central European Business Review*, 2019 [35].

Pada tahap awal, *FB Prophet* menggunakan analisis untuk mengidentifikasi parameter-parameter yang diperlukan, dengan memberikan interpretasi subjektif terhadap parameter. Setelah itu, prosesnya dijalankan secara otomatis, di mana peramalan kemudian akan disimulasikan dan tingkat keakuratannya diukur. Jika tingkat keakuratan belum memenuhi kriteria seperti kurang optimal atau terdapat masalah dengan elemen-elemen lain dalam peramalan, masalah tersebut akan kembali diidentifikasi dan dianalisis, yang umumnya didahulukan berdasarkan urutan prioritas. Setelah itu, analis dapat memeriksa model secara visual dan melakukan penyesuaian [35].

A *Trend* atau *Growth*

Pada *trend* algoritma *Facebook Prophet* terdapat penggunaan dua fungsi yang bergantung kepada model *growth*. Jadi apabila model *growth logistic / non-*

linear maka akan menggunakan model *saturating growth*, sedangkan jika model *growth linear* maka akan menggunakan model *piece-wise* [36].

1. *Saturating Growth (Non-linear)*

Ketika data yang diharapkan akan terus berubah, maka model *non-linear* ini digunakan. Pola pada pertumbuhan ini umumnya mirip seperti pertumbuhan dalam ekosistem alam. Karena pertumbuhan tersebut cenderung tidak konstan atau tidak *linear*, batas atas dan bawah akan digunakan.

2. *Piece-wise Growth (Linear)*

Sedangkan ketika data memiliki pola pertumbuhan yang *linear* atau konstan, maka model *linear* ini digunakan untuk dapat menunjukkan perubahan secara bertahap. Dengan kata lain, model akan menambahkan titik baru ke dalam tren jika ada perubahan dalam tren.

B Seasonality

Dalam model *Facebook Prophet*, fungsi *Fourier* menunjukkan *seasonality*, yang dapat memprediksi pola yang berulang secara periodik, seperti mingguan, bulanan, atau tahunan. Fungsi *Fourier* digunakan karena memberikan model periodik yang fleksibel dan memungkinkan pengumpulan pola yang kompleks dari data.

Facebook Prophet secara *default* memberikan nilai *order* $N=3$ untuk mingguan dan $N=10$ untuk tahunan. Efek musiman dapat disesuaikan dengan periode N ; jika periode N ditingkatkan, pola musiman akan berubah dengan cepat. Risiko *overfitting*, di mana model menjadi terlalu kompleks sehingga tidak dapat digeneralisasi dengan baik pada data baru, dapat meningkat dengan adanya peningkatan terhadap periode [37].

C Holidays atau Event

Efek *holidays* atau *event* seringkali juga memiliki dampak yang dapat mempengaruhi efek deret waktu, karena terkadang tidak selalu mengikuti pola periodik yang jelas. *Facebook prophet model* memperhitungkan efek dari hari libur dengan mengasumsikan bahwa efeknya bersifat independen, serta memberikan keleluasaan untuk dapat menambahkan *event* sebelum serta kedepannya, termasuk hari libur, sebagai komponen kustom. Setiap hari libur dapat diidentifikasi dengan

nama unik, dan kemudian dimasukkan ke dalam model untuk memperhitungkan dampaknya.

Untuk *holidays* dan *event*, dapat juga dilakukan mengatur *upper window* dan *lower window*. *Upper window* menunjukkan hari yang ditujukan setelah peristiwa atau liburan berlangsung, dan *lower window* menunjukkan hari yang ditujukan sebelum peristiwa atau liburan berlangsung [38].

Berikut merupakan rumus terkait metrik-metrik yang digunakan dalam perhitungan akurasi.

2.3 Pengukuran Akurasi Model Prediksi

Pengukuran akurasi model prediksi merupakan langkah penting yang dilakukan dalam proses evaluasi dari kinerja suatu model. Beberapa metrik yang digunakan pada penelitian ini untuk membantu dalam mengukur akurasi model adalah *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE).

MAE merupakan metrik yang menghitung rata-rata dari perbedaan absolut antara nilai yang diprediksi dan nilai aktual, memberikan gambaran langsung tentang nilai besarnya *error* dalam satuan yang sama dengan data. Selanjutnya MSE, akan menghitung rata-rata dari kuadrat perbedaan antara nilai yang diprediksi dan nilai aktual, sehingga lebih sensitif terhadap *outlier* dibandingkan MAE. Lalu RMSE adalah akar kuadrat dari MSE yang memberikan penilaian yang lebih seimbang terhadap error besar dan kecil. Sementara itu, MAPE mengukur rata-rata dari persentase kesalahan absolut antara nilai yang diprediksi dan nilai aktual, memberikan perspektif yang lebih intuitif tentang kesalahan relatif. Penggunaan keempat metrik ini dapat membantu dalam memberikan evaluasi yang komprehensif terhadap kinerja model prediksi dalam berbagai kondisi [39].

Berikut merupakan rumus terkait metrik-metrik yang digunakan dalam perhitungan akurasi.

2.3.1 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) mengukur rata-rata dari perbedaan absolut antara nilai yang diprediksi dan nilai aktual. Ini adalah cara yang efektif untuk mengukur akurasi model di berbagai kondisi tanpa mengarahkan perhatian khusus pada *outlier*. MAE memberikan gambaran langsung tentang besarnya error dalam

satuan yang sama dengan data [39].

Berikut merupakan rumus dari metrik perhitungan MAE dan juga keterangan dari masing-masing komponen dapat dilihat pada persamaan 2.7.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.6)$$

n : Jumlah total sampel atau pengamatan dalam dataset.

y_i : Nilai sebenarnya dari pengamatan ke- i .

\hat{y}_i : Nilai prediksi yang dihasilkan oleh model untuk pengamatan ke- i .

$|y_i - \hat{y}_i|$: Nilai absolut dari perbedaan antara nilai sebenarnya dan nilai prediksi untuk pengamatan ke- i .

2.3.2 Mean Squared Error (MSE)

Mean Squared Error (MSE) mengukur rata-rata dari kuadrat perbedaan antara nilai yang diprediksi dan nilai aktual. Metrik ini umum digunakan untuk menilai kinerja model regresi, karena MSE menekankan kesalahan besar lebih daripada kesalahan kecil. Dengan demikian, MSE lebih sensitif terhadap outlier dibandingkan dengan Mean Absolute Error (MAE) [39].

Berikut merupakan rumus dari metrik perhitungan MSE dan juga keterangan dari masing-masing komponen dapat dilihat pada persamaan 2.7.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.7)$$

Berikut adalah keterangan dari masing-masing komponen dalam rumus MSE:

n : Jumlah total sampel atau pengamatan dalam dataset.

y_i : Nilai sebenarnya dari pengamatan ke- i .

\hat{y}_i : Nilai prediksi yang dihasilkan oleh model untuk pengamatan ke- i .

$(y_i - \hat{y}_i)^2$: Kuadrat dari selisih antara nilai sebenarnya dan nilai prediksi.

2.3.3 Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) merupakan hasil pengakaran dari rata-rata kuadrat semua kesalahan prediksi. RMSE lebih sensitif terhadap *outlier* dibandingkan MAE karena mengkuadratkan setiap kesalahan sebelum dirata-ratakan, yang menempatkan bobot lebih besar pada kesalahan yang lebih besar. Ini membuat RMSE berguna ketika kesalahan besar sangat tidak diinginkan [39].

Berikut merupakan rumus dari metrik perhitungan RMSE dan juga keterangan dari masing-masing komponen dapat dilihat pada persamaan 2.8.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.8)$$

Berikut adalah keterangan dari masing-masing komponen dalam rumus RMSE:

n : Jumlah total sampel atau pengamatan dalam dataset.

y_i : Nilai absolut dari pengamatan ke- i .

\hat{y}_i : Nilai prediksi yang dihasilkan oleh model untuk pengamatan ke- i .

$(y_i - \hat{y}_i)^2$: Hasil kuadrat dari perbedaan antara nilai absolut maupun nilai prediksi

2.3.4 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) mengukur kesalahan rata-rata dalam persentase dan memberikan pemahaman tentang kesalahan sebagai persentase dari nilai yang sebenarnya. Ini sangat berguna untuk memberikan interpretasi kesalahan yang intuitif dalam hal ukuran relatif kesalahan terhadap nilai yang sebenarnya [39].

Berikut merupakan rumus dari metrik perhitungan MAPE dan juga keterangan dari masing-masing komponen dalam rumus dapat dilihat pada persamaan 2.9.

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.9)$$

Berikut adalah keterangan dari masing-masing komponen dalam rumus MAPE:

n : Jumlah total sampel atau pengamatan dalam dataset.

y_i : Nilai sebenarnya dari pengamatan ke- i .

\hat{y}_i : Nilai prediksi yang dihasilkan oleh model untuk pengamatan ke- i .

$\left| \frac{y_i - \hat{y}_i}{y_i} \right|$: adalah nilai absolut dari persentase kesalahan antara nilai sebenarnya dan prediksi untuk pengamatan ke- i .

Semakin rendah nilai MAPE yang didapatkan, maka semakin akurat estimasi yang dihasilkan, menunjukkan bahwa model peramalan yang digunakan efektif. Interpretasi nilai MAPE dapat dilihat pada Tabel 2.1.

Tabel 2.1. Interpretasi Nilai MAPE

MAPE (%)	Interpretasi
<10	Prediksi sangat akurat
10 - 20	Prediksi yang baik
20 - 50	Prediksi yang layak
>50	Prediksi yang tidak akurat

MAPE memiliki tingkat interpretasi dimana dapat menunjukkan tingkat kelayakan untuk hasil Prediksi. Ketika Nilai presentase MAPE kurang dari sama dengan 10% maka Hasil peramalan sangat akurat, tetapi jika nilai MAPE berada diatas 50% maka hasil peramalan dianggap tidak akurat atau tidak cocok untuk dijadikan sebagai hasil peramalan [40].

