

BAB 2

LANDASAN TEORI

2.1 Beras

Beras ialah makanan utama yang berasal dari tanaman padi yang ditanam di sawah. Setelah dimasak atau ditanak, beras menjadi nasi yang dikonsumsi sehari-hari oleh penduduk Indonesia kebanyakan. Tipe beras yang biasa digunakan untuk dihidangkan dalam harian yaitu beras putih. Terdapat jenis-jenis beras putih yang terdapat di pasar yang dimakan masyarakat Indonesia. Berbagai jenis dari beras tersebut menyajikan aroma, rasa, serta harga berbeda pula. Umumnya untuk memperoleh beras, gabah yang sudah dipanen dipukul-pukul dengan alat untuk memisahkan dari merangnya, setelahnya gabah dijemur agar kering, serta gabah digiling agar padi terpisah dari beras. Barulah selanjutnya beras dapat dipasarkan (Ricardo & Gasim, 2019).

Beras ialah bagian bulir padi (gabah) yang sudah terkelupas dari sekam. Beras merupakan hasil olahan dari produk pertanian yang dikenal sebagai padi (*Oryza Sativa*). Tanaman ini biasanya memiliki karakteristik setinggi 1 sampai 1,8 m dan daunnya memiliki panjang 50 sampai 100 cm. Ada banyak cara untuk menggolongkan beras, yaitu berdasarkan varietas padi, seperti beras Bramo Super, Rojo Lele, beras Ramos dan lain sebagainya. Ada pula pengelompokan beras yang berdasarkan asal daerahnya, seperti beras Cianjur, beras Garut dan beras Banyuwangi (Mukhlisin et al., 2019).

2.2 Penambangan Data (*Data Mining*)

Data mining yang juga dikenal sebagai penemuan pengetahuan dalam basis data (KDD) adalah proses yang mencakup pengumpulan dan analisis data historis untuk mengidentifikasi pola dan keteraturan dalam kumpulan data yang besar. Hasil dari *data mining* dapat dimanfaatkan untuk mendukung pengambilan keputusan di masa depan. Proses ini menggabungkan elemen-elemen dari statistik, kecerdasan buatan, dan riset basis data yang terus berkembang. *Data mining* berfungsi sebagai alat untuk menganalisis data dalam ukuran yang besar guna menemukan hubungan

yang jelas dan menarik kesimpulan tentang informasi yang sebelumnya tidak diketahui (Pratama et al., 2022).

Data mining (penambangan data) adalah proses analisis terhadap kumpulan data yang biasanya dalam jumlah yang besar untuk mengidentifikasi hubungan antar data dan menyajikannya dalam format yang mudah dipahami serta mudah digunakan. Hasil dari analisis ini sering kali berupa *models* (model) ataupun *patterns* (pola)

Secara ringkas, penambangan data merupakan proses untuk menemukan pola-pola tertentu dalam data atau basis data yang besar guna mendapatkan informasi yang bermanfaat. Beberapa jenis atau teknik dalam penambangan data meliputi *association*, *classification*, dan *clustering*. Teknik *association* berfokus pada pencarian pola hubungan dalam data, sementara *classification* dan *clustering* lebih menekankan pada pengelompokan pola-pola yang ada (Prasetyowati, 2019).

2.2.1 Tahapan Data Mining

Data mining merupakan bagian dari serangkaian proses yang dapat dibagi menjadi beberapa tahap. Tahapan ini bersifat interaktif, di mana pengguna berpartisipasi secara langsung atau melalui basis pengetahuan. Tahapan-tahapan dalam penemuan pengetahuan dari basis data (Yuli Mardi, 2019) dijelaskan sebagai berikut:

1. *Data selection*

Sebelum memulai tahap penggalian informasi dalam *knowledge data discovery*, penting untuk melakukan pemilihan data dari kumpulan data operasional yang ada. Data yang telah diseleksi ini kemudian disimpan dalam berkas terpisah dari basis data operasional untuk digunakan dalam proses penambangan data.

2. *Pre-processing/Cleaning*

Sebelum melaksanakan proses penambangan data, diperlukan langkah pembersihan pada data yang menjadi fokus dalam *knowledge data discovery*. Proses ini mencakup penghapusan data ganda, pemeriksaan konsistensi data, serta perbaikan kesalahan yang mungkin ada, seperti

kesalahan tipografi. Selain itu, juga dilakukan proses *enrichment*, yaitu menambah nilai pada data yang sudah ada dengan informasi atau data lain yang relevan dan diperlukan untuk *knowledge data discovery*, termasuk data eksternal.

3. *Transformation*

Proses *coding* adalah tahap transformasi data yang telah dipilih, sehingga data tersebut siap untuk digunakan dalam proses penambangan data. *Coding* dalam *knowledge data discovery* merupakan langkah kreatif yang sangat bergantung pada jenis atau pola informasi yang ingin dicari dalam basis data.

4. *Data mining*

Data mining adalah proses untuk menemukan pola atau informasi menarik dalam data yang telah dipilih dengan menggunakan berbagai teknik atau metode. Teknik, metode, atau algoritma yang digunakan dalam *data mining* sangat beragam. Pemilihan metode atau algoritma yang tepat tergantung pada tujuan dan keseluruhan proses *knowledge data discovery*.

5. *Interpretation/Evaluation*

Pola informasi yang dihasilkan dari proses penambangan data perlu disajikan dalam format yang mudah dipahami oleh pihak yang berkepentingan. Tahap ini dikenal sebagai interpretasi dalam *knowledge data discovery*. Proses ini mencakup pemeriksaan apakah pola atau informasi yang ditemukan sesuai dengan fakta atau hipotesis yang ada sebelumnya, sehingga menghasilkan pengetahuan yang dapat disampaikan kepada pengguna.

2.2.2 **Pengelompokan *Data Mining***

Terdapat kelompok-kelompok dalam penambangan data yang sesuai dengan tugas yang dilaksanakan, (Prasetyowati, 2019) diantaranya:

1. Deskripsi

Deskripsi berfungsi untuk menggambarkan pola dan kecenderungan yang terdapat dalam data.

2. Estimasi

Penggolongan data menggunakan variabel target lebih bersifat numerik. Hasil dari model tersebut dapat diaplikasikan pada berbagai masalah penambangan data lainnya.

3. Prediksi

Nilai yang dihasilkan berhubungan dengan keadaan atau data di masa yang akan datang. Metode atau teknik dalam klasifikasi serta estimasi dapat digunakan untuk melakukan prediksi pada situasi atau kasus yang relevan.

4. Klasifikasi

Dalam klasifikasi, terdapat variabel target dalam bentuk kategori. Misalnya, penggolongan pendapatan dapat dibagi menjadi tiga kategori: pendapatan tinggi, sedang, dan rendah..

5. Pengklasteran

Pengklasteran ialah proses pengelompokan *record*, pengamatan, atau memperhatikan serta membentuk kelas beberapa objek atau data berdasarkan kesamaan dengan cara membagi semua data yang ada dan bersifat tanpa arahan (*unsupervised*).

6. Asosiasi

Asosiasi adalah metode untuk menemukan atribut yang muncul bersamaan. Analisis asosiasi didefinisikan sebagai proses untuk menemukan semua aturan asosiatif yang memenuhi batasan minimum untuk dukungan (*support*) dan kepercayaan (*confidence*).

2.3 Pembelajaran Mesin (*Machine Learning*)

Pembelajaran mesin atau *machine learning*, merupakan bidang ilmu yang berfokus terhadap pengembangan sistem yang mampu belajar dan meningkatkan kemampuannya secara otomatis. Kemampuan ini terjadi karena *machine learning* dapat mengidentifikasi pola dan tren dalam data, serta membuat prediksi dan keputusan berdasarkan pembelajaran tersebut. Dalam *machine learning*, metode klasifikasi dan regresi sering digunakan untuk membantu sistem belajar dan membuat prediksi yang akurat (Mukhlis et al., 2024).

Pembelajaran mesin muncul sebagai pendekatan yang penting dan inovatif untuk memungkinkan komputer belajar dari data dan membuat keputusan atau prediksi secara otomatis tanpa harus diprogram secara eksplisit. Paradigma ini bertumpu pada pengembangan algoritma dan model statistik yang memungkinkan sistem untuk meningkatkan kinerjanya seiring dengan meningkatnya pengalaman yang diperoleh dari data yang dihadapinya.

2.3.1 Tahapan Proses *Machine Learning*

Proses pembelajaran mesin melibatkan serangkaian langkah terstruktur dan sistematis yang penting untuk membantu mesin belajar pola dari data, membuat prediksi, atau mengambil keputusan.

Langkah pertama dalam proses pembelajaran mesin adalah mengumpulkan data yang relevan untuk digunakan dalam melatih model. Sumber data dapat bervariasi, mulai dari basis data internal hingga data publik atau data yang dikumpulkan secara langsung. Setelah data terkumpul, langkah selanjutnya adalah mempersiapkan data dengan membersihkan, mentransformasi, dan menangani nilai-nilai yang hilang atau outlier.

Setelah data dipersiapkan, langkah berikutnya adalah memilih algoritma yang paling cocok untuk kasus penggunaan tertentu. Pemilihan algoritma bergantung pada jenis masalah yang dihadapi (seperti klasifikasi, regresi, atau pengelompokan) dan karakteristik data yang ada.

Langkah berikutnya adalah melatih model dengan menggunakan data latih yang telah disiapkan sebelumnya. Model akan belajar dari data latih untuk mengenali pola-pola dalam data dan membuat prediksi atau keputusan yang relevan. Proses pelatihan melibatkan penyesuaian parameter-parameter model agar kesalahan prediksi model dapat diminimalkan.

Setelah itu, model yang telah dilatih akan dievaluasi menggunakan data uji yang tidak digunakan sebelumnya. Tujuannya adalah untuk menilai seberapa baik model mampu menerapkan pola-pola yang telah dipelajari dari data latih ke data baru. Jika hasil evaluasi tidak sesuai harapan, maka model perlu dioptimalkan dan disesuaikan lebih lanjut. Hal ini dapat melibatkan pemilihan fitur yang lebih baik,

penyesuaian parameter-model, atau penerapan teknik-teknik seperti peningkatan hiperparameter.

2.3.2 Pendekatan *Machine Learning*

Dalam pembelajaran mesin (*machine learning*), terdapat beberapa pendekatan utama yang digunakan untuk mengembangkan model yang dapat belajar dari data. Berikut adalah beberapa pendekatan penting dalam pembelajaran mesin (Mukhlis et al., 2024).

1. Pembelajaran *Supervised* (Terawasi).

Dalam pembelajaran terawasi, model belajar dari pasangan data yang berisi *input* dan *output* yang sesuai. Model menggunakan data ini untuk mempelajari hubungan antara *input* dan *output*, sehingga dapat membuat prediksi atau mengklasifikasikan data baru. Contoh algoritmanya adalah Regresi Linier, *K-Nearest Neighbors* (KNN), *Decision Trees*, *Support Vector Machines* (SVM) dan *Neural Networks*.

2. Pembelajaran *Unsupervised* (Tidak Terawasi)

Dalam pembelajaran tidak terawasi, model tidak memiliki informasi target yang tepat dalam data. Tujuan utama adalah menemukan struktur atau pola yang tersembunyi dalam data. Contoh algoritmanya adalah *K-Means Clustering*, *Hierarchical Clustering*, *Principal Component Analysis* (PCA).

3. Pembelajaran *Semi-Supervised* (Semi-Terawasi)

Pembelajaran semi-terawasi menggabungkan elemen-elemen dari pembelajaran terawasi dan tidak terawasi. Ini terjadi ketika hanya sebagian data memiliki label, sementara sebagian lainnya tidak. Algoritma ini mencoba memanfaatkan informasi dari data yang tidak berlabel untuk meningkatkan kinerja model.

4. Pembelajaran Penguatan (*Reinforcement Learning*)

Dalam pembelajaran penguatan, agen belajar melalui interaksi dengan lingkungannya. Tujuan agen adalah memaksimalkan akumulasi penghargaan atau meminimalkan hukuman. Agar agen dapat belajar, mereka diberi umpan balik dalam bentuk penghargaan atau hukuman

setelah melakukan tindakan tertentu. Contoh algoritmanya adalah *Q-Learning*, *Deep QNetworks (DQN)* dan *Actor-Critic*.

5. Pembelajaran Transfer (*Transfer Learning*)

Pembelajaran transfer melibatkan mentransfer pengetahuan dari satu tugas ke tugas lain yang terkait. Ini berguna ketika memiliki sedikit data untuk tugas baru atau ketika ingin meningkatkan kinerja model pada tugas tertentu. Contohnya Menggunakan model yang telah dilatih pada dataset besar untuk mengekstrak fitur pada dataset kecil, dan kemudian melatih model baru pada dataset kecil tersebut.

Setiap pendekatan memiliki keunggulan dan kelemahan tertentu tergantung pada jenis data, masalah yang dihadapi, dan tujuan pemodelan. Oleh karena itu, pemilihan pendekatan yang tepat sangat bergantung pada konteks spesifik masalah dan sumber daya yang tersedia (Mukhlis et al., 2024).

2.3.3 Kaitan Antara *Machine Learning* Dan *Data Mining*

Machine learning dan *data mining* merupakan dua bidang yang saling berkaitan dalam ilmu data. Keduanya berkonsentrasi terhadap ekstraksi pengetahuan dari data dengan pendekatan berbeda. *Data mining* merupakan proses menemukan pola serta wawasan tersembunyi dalam kumpulan data yang besar.

Tujuannya yaitu untuk mengubah data mentah menjadi informasi yang akan digunakan untuk membuat keputusan yang lebih baik. *Machine learning* merupakan bagian dari kecerdasan buatan yang memungkinkan komputer untuk belajar dari data. Algoritma *machine learning* dilatih terhadap kumpulan data untuk mempelajari pola serta membuat prediksi (Mukhlis et al., 2024).

Data mining dan *machine learning* sering digunakan bersama-sama guna memecahkan masalah. *Data mining* dapat digunakan untuk menyiapkan data bagi *machine learning*, dan *machine learning* dapat digunakan untuk membuat prediksi serta wawasan dari data yang sudah ditambang. Kaitannya anatar lain:

1. *Data mining* dan *machine learning* saling berkaitan dikarenakan *data mining* dapat difungsikan sebagai tahapan awal terhadap proses *machine learning*.

2. *Data mining* membantu mengidentifikasi pola serta wawasan dari data yang kemudian bisa digunakan sebagai sebuah masukan untuk model *machine learning*.
3. Disisi lain, *machine learning* menggunakan algoritma untuk membangun model yang bisa memprediksi atau mengklasifikasikan data baru.

Meskipun berbeda, *data mining* dan *machine learning* dapat saling melengkapi dalam analisis data. *Data mining* digunakan untuk mengeksplorasi dan menggali wawasan dari data, sementara *machine learning* memanfaatkan wawasan tersebut untuk mengembangkan model yang lebih cerdas serta adaptif. (Putra et al., 2023)

2.4 Regresi

Regresi ialah suatu metode statistik dengan fungsi untuk menelaah korelasi antara satu atau lebih variabel independen (prediktor) dengan variabel dependen (target), serta untuk mengestimasi nilai variabel dependen berdasarkan variabel independent (Mukhlis et al., 2024).

Tujuan regresi yang paling utama ialah membangun model yang menjabarkan kaitan antar variabel tersebut sehingga dapat dilakukan prediksi atau estimasi terhadap nilai variabel dependen disesuaikan terhadap nilai variabel independen yang diberikan. Dengan demikian, regresi ialah sebuah cara analisis statistik dengan tujuan untuk memahami kaitan antar variabel serta untuk memprediksi nilai variabel dependen terhadap variabel independen.

2.4.1 Tujuan Regresi

Terdapat beberapa tujuan regresi berdasarkan bentuk kaitan antara variabel independen dan variabel dependen. Diantaranya adalah beberapa tujuan dari regresi:

1. Mengidentifikasi Hubungan

Regresi difungsikan untuk mengenali serta membentuk kaitan variabel dependen dan variabel independen. Dengan demikian, dapat dipahami cara variabel-variabel itu saling berhubungan.

2. Prediksi

Regresi difungsikan untuk memprediksi nilai variabel dependen terhadap nilai variabel independen yang diajukan. Dengan memahami hubungan antar variabel tersebut, dapat membuat estimasi atau prediksi yang akurat.

3. Penjelasan Variabilitas

Regresi digunakan untuk menjelaskan variabilitas variabel dependen dengan variabel independen. Dengan memahami kontribusi variabel independen terhadap variabel dependen, dapat membantu menjelaskan faktor-faktor yang mempengaruhi variabilitas data.

4. Validasi Model

Regresi digunakan untuk menguji serta memvalidasi model. Dengan melakukan evaluasi kepada model regresi, dapat menilai kecocokan model serta ketepatannya dalam memprediksi nilai variabel dependen.

2.4.2 Jenis-Jenis Masalah Regresi

Terdapat beberapa jenis masalah regresi berdasarkan bentuk kaitan variabel independen dan variabel dependen. Diantaranya ialah beberapa jenis teknik regresi yang sering dipakai:

1. Regresi Linear

Regresi linear ialah metode regresi yang difungsikan guna membentuk hubungan linier antara variabel independen dan variabel dependen. Contohnya adalah prediksi harga rumah berdasarkan luas tanah.

2. Regresi Non-Linear

Regresi non-linear yaitu regresi yang difungsikan ketika kaitan antara variabel independen dan variabel dependen tidak linier. Contohnya dalam memprediksi pertumbuhan populasi dengan model logistik.

3. Regresi Polinomial

Regresi polinomial merupakan regresi yang menggunakan fungsi polinomial dalam memodelkan kaitan antara variabel independen serta variabel dependen. Contohnya dalam memprediksi tingkat kepuasan pelanggan berdasarkan faktor-faktor tertentu.

4. Regresi Ridge dan Lasso

Regresi ridge dan lasso adalah model regresi yang dipakai untuk mengatasi masalah kolinearitas ganda serta untuk melakukan regularisasi terhadap model. Contohnya pada prediksi harga saham dengan mengontrol overfitting.

5. Regresi Logistik

Regresi Logistik yaitu jenis regresi yang difungsikan sebagai membentuk hubungan antara variabel independent dan variabel dependen biner. Contohnya dalam memprediksi apakah konsumen membeli produk ataukah tidak.

6. Regresi *Time Series*

Regresi *time series* merupakan regresi yang difungsikan guna memprediksi data berdasarkan rentang waktu. contohnya dalam memprediksi penjualan bulanan berdasarkan riwayat data.

Setiap jenis regresi memiliki kegunaan dan penerapan yang berbeda tergantung pada sifat data serta tujuan analisis. Pemilihan model regresi yang sesuai teramat penting guna memodelkan hubungan yang tepat antara variabel-variabel dan membuat prediksi yang tepat (Mukhlis et al., 2024).

2.5 Peramalan (*Forecasting*)

Peramalan adalah proses pemikiran tentang suatu nilai, contohnya seperti permintaan terhadap sebuah produk atau beberapa produk pada masa yang akan datang. Pada hakekatnya peramalan hanyalah sebuah dugaan (*guess*), akan tetapi dengan penerapan teknik-teknik tertentu peramalan mejadi lebih dari sekedar dugaan.

Peramalan dapat dianggap sebagai estimasi yang berdasarkan pengetahuan ilmiah (*educated guess*). Setiap keputusan yang akan diambil di masa depan pasti didasarkan pada peramalan (Hudaningsih et al., 2020). Peramalan merupakan kombinasi antara pengetahuan dan keterampilan dalam memperkirakan apa yang mungkin terjadi di masa depan pada saat ini.

Dalam melakukan peramalan, penting untuk memiliki data dan informasi dari masa lalu. Data dan informasi ini mencerminkan perilaku yang terjadi sebelumnya dalam berbagai kondisi pada saat itu. Dalam praktiknya, terdapat beberapa kategori peramalan yang dapat digunakan. Diantaranya sebagai berikut (Krisma et al., 2019) :

1. Berdasarkan cara penyusunannya:
 - a. Peramalan Subjektif adalah peramalan yang bergantung pada intuisi atau perasaan individu yang menyusunnya. Dalam hal ini, pengalaman dan pandangan masa lalu dari penyusun sangat mempengaruhi hasil ramalan.
 - b. Peramalan objektif adalah peramalan yang didasarkan pada data dan informasi yang ada, yang kemudian dianalisis dengan metode-metode tertentu. Data yang digunakan biasanya berasal dari informasi yang terdapat di masa lalu.
2. Berdasarkan sifat ramalan:
 - a. Peramalan kualitatif adalah peramalan yang berdasarkan data kualitatif dan umumnya peramalan kualitatif ini didasarkan pada hasil dari penelitian.
 - b. Peramalan kuantitatif adalah peramalan yang didasarkan pada data kuantitatif dari masa lampau (berupa angka).
3. Berdasarkan jangka waktu:
 - a. Peramalan jangka pendek (*short term forecasting*) ialah peramalan yang dilakukan untuk periode waktu yang singkat, seperti setiap jam, harian, atau mingguan.
 - b. Peramalan jangka menengah (*mid term forecasting*) ialah peramalan yang dilakukan untuk periode waktu yang lebih panjang, yaitu mingguan hingga bulanan.
 - c. Peramalan jangka panjang (*long term forecasting*) ialah peramalan yang dilakukan untuk periode waktu yang lebih lama, yaitu bulanan hingga tahunan.

2.6 Persediaan

Pengertian persediaan dapat diartikan dalam berbagai konteks, seperti persediaan yang ada pada saat tertentu, daftar rinci mengenai barang yang tersedia, atau total jumlah barang yang dimiliki oleh suatu organisasi pada waktu tertentu. (Irfan, 2021).

Pengelolaan sistem persediaan yang efektif akan memastikan bahwa proses produksi berjalan lancar dan jumlah persediaan tidak membebani gudang bahan baku. Sebaliknya, jika persediaan tidak dikelola dengan baik, hal ini dapat berdampak pada meningkatnya biaya yang dikeluarkan oleh perusahaan. Biaya persediaan memiliki proporsi yang signifikan terhadap total biaya perusahaan.

Terdapat beberapa fungsi penting dari persediaan terhadap perusahaan, yaitu (Ali & Bintang, 2022):

1. Untuk memenuhi permintaan yang diperkirakan akan muncul.
2. Untuk menyeimbangkan antara produksi dan distribusi.
3. Untuk mendapatkan keuntungan dari potongan harga, karena membeli dalam jumlah besar sering kali mendapatkan diskon.
4. Untuk mencegah kekurangan persediaan yang mungkin disebabkan oleh cuaca, kekurangan pasokan, kualitas, atau keterlambatan pengiriman.
5. Untuk memastikan kelangsungan operasi dengan cara melakukan pengelolaan persediaan.

2.7 Nilai Ketepatan Peramalan

Tingkat kesalahan dalam perhitungan peramalan dapat diukur menggunakan *Mean Absolute Deviation* (MAD), *Mean Squared Error* (MSE), dan *Mean Absolute Percentage Error* (MAPE). Metode-metode ini memberikan ukuran akurasi yang dapat digunakan untuk membandingkan berbagai metode peramalan yang mungkin diterapkan.

2.7.1 *Mean Absolute Deviation* (MAD)

Metode untuk mengevaluasi teknik peramalan dapat dilakukan dengan menghitung jumlah kesalahan absolut. *Mean Absolute Deviation* (MAD) digunakan

untuk menilai akurasi ramalan dengan menghitung rata-rata dari kesalahan yang dihasilkan (nilai absolut dari setiap kesalahan). MAD sangat berguna karena mengukur kesalahan ramalan dalam satuan yang sama dengan data asli (Ginantra & Anandita, 2021). Berikut rumus perhitungan dari *Mean Absolute Deviation* (MAD) dinyatakan pada persamaan 2.1:

$$MAD = \sum_{t=1}^n \left| \frac{A_t - F_t}{n} \right| \dots\dots\dots (2.1)$$

Dimana:

A_t = Nilai data aktual pada periode t

F_t = Nilai peramalan pada periode t

n = Jumlah data

2.7.2 Mean Squared Error (MSE)

Metode lain untuk mengevaluasi teknik peramalan adalah dengan mengkuadratkan setiap kesalahan atau sisa, kemudian menjumlahkannya dan membaginya dengan jumlah observasi. Pendekatan ini memberikan bobot lebih pada kesalahan yang lebih besar karena kesalahan tersebut dikuadratkan. Metode ini cenderung menghasilkan nilai kesalahan yang lebih rendah untuk kesalahan kecil, tetapi bisa menyebabkan perbedaan yang signifikan dalam beberapa kasus (Ginantra & Anandita, 2021). Secara matematis, *Mean Squared Error* (MSE) dapat dinyatakan dalam persamaan 2.2 berikut:

$$MSE = \sum_{t=1}^n \left| \frac{(A_t - F_t)^2}{n} \right| \dots\dots\dots (2.2)$$

A_t = Nilai data aktual pada periode t

F_t = Nilai peramalan pada periode t

n = Jumlah data

2.7.3 Mean Absolute Percentage Error (MAPE)

Dihitung dengan cara mengambil kesalahan mutlak untuk setiap periode, kemudian membaginya dengan nilai observasi yang sebenarnya untuk periode tersebut. Setelah itu, rata-rata dari kesalahan persentase mutlak tersebut dihitung.

Metode ini berguna ketika ukuran atau besar variabel yang diramalkan menjadi penting dalam menilai akurasi ramalan. MAPE menunjukkan seberapa besar kesalahan dalam peramalan dibandingkan dengan nilai yang sebenarnya (Ginatra & Anandita, 2021). Perhitungan nilai MAPE dapat dihitung menggunakan persamaan 2.3:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{(A_t - F_t)}{A_t} \right| \times 100\% \dots\dots\dots (2.3)$$

Dimana:

A_t = Nilai data aktual pada periode t

F_t = Nilai peramalan pada periode t

n = Jumlah data

2.8 Metode *Single Exponential Smoothing*

Dalam metode *Exponential Smoothing*, peramalan dilakukan secara berulang dengan memakai data terbaru, di mana setiap data diberikan bobot. *Exponential Smoothing* merupakan salah satu teknik peramalan rata-rata bergerak yang memberikan penimbangan secara eksponensial terhadap data masa lalu. Metode ini merupakan pengembangan dari metode *moving average*. *Exponential Smoothing* mencakup serangkaian teknik yang memberikan bobot menurun secara eksponensial pada nilai observasi yang lebih lama. Karena itu, metode ini dikenal sebagai prosedur pemulusan.

Metode ini terdiri dari tiga jenis, yaitu *Single Exponential Smoothing*, *Double Exponential Smoothing*, dan *Triple Exponential Smoothing* (Nuryani & Rudianto, 2022). Dalam penelitian ini, metode yang digunakan adalah *Single Exponential Smoothing*. Metode ini memberikan bobot yang menurun secara eksponensial terhadap nilai observasi yang lebih lama, di mana nilai yang lebih baru mendapatkan bobot yang lebih besar dibandingkan dengan nilai observasi yang lebih tua.

Metode *Single Exponential Smoothing* menghasilkan pembobotan eksponensial rata-rata dari semua nilai observasi yang telah ada sebelumnya. Metode ini tidak dipengaruhi oleh tren atau faktor musiman. *Single Exponential*

Smoothing biasanya digunakan untuk peramalan jangka pendek, umumnya hanya untuk satu periode ke depan. Berikut adalah rumus untuk metode *Single Exponential Smoothing*. (Chaerunnisa & Momon, 2021):

$$F_t = F_{t-1} + \alpha(A_{t-1} - F_{t-1}) = \alpha A_{t-1} + (1 - \alpha)F_{t-1} \dots\dots\dots (2.4)$$

Dimana:

F_t = Peramalan pada periode waktu t

F_{t-1} = Peramalan pada priode waktu $t-1$

α = konstanta smoothing antara 0 sampai 1

A_{t-1} = Nilai aktual untuk priode $t-1$

2.9 Penerapan Metode *Single Exponential Smoothing*

Single Exponential Smoothing adalah salah satu metode peramalan yang menggunakan rata-rata bergerak dengan memberikan bobot eksponensial pada data historis. Metode ini berasumsi bahwa data yang lebih lama akan memiliki bobot yang semakin kecil seiring dengan jaraknya dari data terbaru.

Dengan demikian, jika data terakhir berasal dari bulan Oktober, maka data bulan September dianggap lebih signifikan dan diberikan bobot yang lebih besar dalam proses peramalan dibandingkan dengan data dari bulan Agustus. Data perhitungan model *Single Exponential Smoothing* menggunakan data penjualan Kecap Manis Merk Bango 620 ml yang akan dijelaskan sebagai berikut.

Perhitungan *Single Exponential Smoothing* dilakukan dengan cara menentukan besaran konstanta smoothing (α) dan initial value terlebih dahulu. Peneliti menentukan initial value diambil dari data bulan pertama. Sebagai contoh pada penelitian (Atkha and Rusdah, 2019), data bulan pertama pada penjualan Kecap Manis Merk Bango 620 ml adalah 33, 31, 37, 35, 25, 28, 26, 34, 37, 27, 45, 23 hasil data penjualan di bulan pertama tersebut menjadi *initial value* (F_1) predict pada bulan Januari sebesar 33.

$$F_1 = 33$$

Selanjutnya, untuk menghitung nilai *predict* pada bulan berikutnya (F_2, F_3, \dots, F_n), menggunakan rumus *Single Exponential Smoothing* dengan menggunakan konstanta *smoothing* (α) dari 0,1 sampai 0,9.

$$F_2 = 33,00 + 0.1 * (33 - 33,00) = 33,00$$

$$F_3 = 33,00 + 0.1 * (31 - 33,00) = 32,80$$

$$F_4 = 32,80 + 0.1 * (37 - 32,80) = 33,22$$

$$F_5 = 33,22 + 0.1 * (35 - 33,22) = 33,40$$

$$F_6 = 33,40 + 0.1 * (25 - 33,40) = 32,56$$

$$F_7 = 32,56 + 0.1 * (28 - 32,56) = 32,10$$

$$F_8 = 32,10 + 0.1 * (26 - 32,10) = 31,49$$

$$F_9 = 31,49 + 0.1 * (34 - 31,49) = 31,74$$

$$F_{10} = 31,74 + 0.1 * (37 - 31,74) = 32,27$$

$$F_{11} = 32,27 + 0.1 * (27 - 32,27) = 31,74$$

$$F_{12} = 31,74 + 0.1 * (45 - 31,74) = 33,07$$

Hasil perhitungan peramalan kecap manis merk Bango 620ml dengan metode *Single Exponential Smoothing* menggunakan *Alpha* 0,1 dapat dilihat pada table 2.1 berikut:

Table 2.1 Perhitungan dengan *Alpha* 0.1

No.	Periode (t)	Aktual (A)	Predict ($\alpha=0.1$)
		A	F
1.	Januari	33	
2.	Februari	31	33
3.	Maret	37	32,8
4.	April	35	33,22
5.	Mei	25	33,40
6.	Juni	28	32,56
7.	Juli	26	32,10
8.	Agustus	34	31,49
9.	September	37	31,74
10.	Oktober	27	32,27
11.	November	45	31,74
12.	Desember	23	33,07

Langkah berikutnya adalah menghitung nilai kesalahan dari peramalan yang telah dilakukan. Proses ini dikenal sebagai pengukuran akurasi. Beberapa nilai kesalahan yang akan dihitung meliputi *Mean Absolute Deviation* (MAD), *Mean Absolute Percentage Error* (MAPE), dan *Mean Square Error* (MSE).

Nilai *Mean Absolute Deviation* (MAD) diperoleh dengan menjumlahkan selisih antara nilai aktual dan nilai prediksi, lalu membaginya dengan jumlah data. Sementara itu, *Mean Absolute Percentage Error* (MAPE) dihitung dari MAD dengan cara membagi selisih antara nilai aktual dan prediksi dengan nilai aktual, kemudian dikalikan 100% dan dibagi dengan jumlah data. Untuk menghitung *Mean Square Error* (MSE), kita mengambil selisih antara nilai aktual dan prediksi, mengkuadratkan hasilnya, dan membaginya dengan jumlah data. Hasil perhitungan untuk peramalan Kecap Manis Merk Bango 620ml dapat dilihat pada tabel 2.2.

Table 2.2 Hasil MAD, MAPE, MSE Dengan *Alpha* 0.1

No.	Periode (t)	MAD	MAPE	MSE
		A-F	A-F /A	(A-F) ²
1.	Januari	0	0	0
2.	Februari	2	0,06	4
3.	Maret	4,2	0,11	17,64
4.	April	1,78	0,05	3,17
5.	Mei	8,4	0,34	70,56
6.	Juni	4,56	0,16	20,79
7.	Juli	6,1	0,23	37,21
8.	Agustus	2,51	0,07	6,3
9.	September	5,26	0,14	27,67
10.	Oktober	5,27	0,20	27,77
11.	November	13,26	0,29	175,83
12.	Desember	10,07	0,44	101,4
Total		63,41	2,11	492,34
MAD		5.28		
MAPE		17.58%		
MSE		41.02		

Dengan melakukan perhitungan tersebut, diperoleh hasil peramalan penjualan Kecap Manis Merk Bango 620ml untuk bulan Januari adalah sebagai berikut:

$$\begin{aligned} F_{13} &= F_{12} + \alpha *(A_{12} - F_{12}) \\ &= 33,07 + 0.1 * (23 - 33,07) \\ &= 32,06 \text{ (dibulatkan menjadi 32)} \end{aligned}$$

Dengan nilai *error* MAD 5.28, MAPE 17.58% dan MSE 41.02. Perhitungan *Single Exponential Smoothing* dan perhitungan nilai *error* tersebut dilakukan sampai nilai konstanta penghalusan (α) = 0.9.

Setelah melakukan perhitungan peramalan dan membandingkan nilai konstanta penghalusan (α) dari 0 hingga 1, langkah berikutnya adalah memilih model. Pemilihan ini didasarkan pada nilai kesalahan terkecil dari model yang telah dikembangkan. Perbandingan nilai kesalahan dari berbagai model tersebut disajikan dalam tabel 2.3.

Table 2.3 Perbandingan Nilai *Error*

Nilai konstanta (α)	MAD	MAPE	MSE
0.1	5.28	17.58	41.02
0.2	5.56	18.13	44.50
0.3	5.74	18.85	48.69
0.4	6.01	19.45	53.17
0.5	6.11	19.95	58.03
0.6	6.25	20.36	63.43
0.7	6.57	20.89	69.61
0.8	6.57	22.07	76.76
0.9	6.92	23.32	85.15

Tabel di atas menunjukkan bahwa perhitungan ramalan penjualan untuk bulan Januari hingga Desember dengan nilai konstanta (α) 0,1 menghasilkan nilai kesalahan terkecil dibandingkan dengan nilai konstanta lainnya. Oleh karena itu, pada pengujian model berikutnya, akan digunakan nilai konstanta penghalusan (α) 0,1 untuk produk Kecap Manis Merk Bango 620ml.

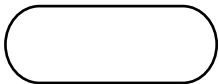
2.10 Flowchart

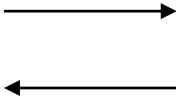


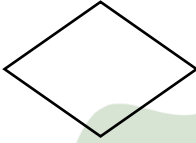
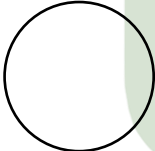
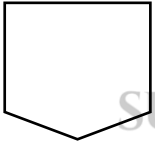

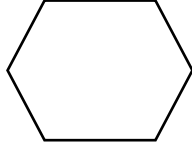
Flowchart adalah representasi grafis yang menunjukkan aliran proses secara sekuensial, baik satu arah maupun dua arah. *Flowchart* digunakan untuk merancang dan merepresentasikan program. Baik *flowchart* maupun algoritma dapat dibuat sebelum atau setelah program dikembangkan. Jika dibuat sebelumnya, keduanya membantu pengembang dalam menentukan alur logika program, sementara jika dibuat setelahnya, mereka berfungsi untuk menjelaskan alur program kepada orang lain. Tujuan utama dari *flowchart* adalah untuk menggambarkan langkah-langkah penyelesaian masalah dengan cara yang sederhana, terstruktur, rapi, dan jelas menggunakan simbol-simbol standar. (Pratiwi, 2020). Beberapa petunjuk yang harus diperhatikan dalam membuat *flowchart*, seperti:

1. *Flowchart* digambarkan dari halaman atas ke bawah dan dari kiri ke kanan.
2. Aktivitas yang digambarkan perlu didefinisikan dengan cermat agar mudah dipahami oleh pembaca.
3. Waktu mulai dan selesai dari setiap aktivitas harus dijelaskan dengan jelas dan rinci.
4. Setiap langkah dalam aktivitas harus dijelaskan rinci menggunakan kata kerja.
5. Urutan langkah-langkah dalam aktivitas harus benar.
6. Lingkup dari aktivitas yang sedang digambarkan harus diteliti dengan seksama.
7. Gunakan simbol-simbol yang sesuai pedoman.

Simbol yang digunakan untuk menggambarkan algoritma dalam bentuk diagram alir yaitu:

Table 2.4 *Flowchart* dan Fungsinya

Simbol	Nama	Fungsi
	<i>Terminator</i>	Menetapkan awal / akhir program

Simbol	Nama	Fungsi
	Garis Alir	Deklarasi sebuah alur / proses program
	Input/Output data	Deklarasi input / output program
	Proses	Deklarasi proses pengolahan data
	<i>Decision</i>	Menentukan kondisi spesifik pemilihan (ya/ tidak)
	<i>On Page Connector</i>	Menghubungkan elemen <i>flowchart</i> di satu halaman
	<i>Off Page Connector</i>	Menghubungkan elemen <i>flowchart</i> pada halaman yang beda
	<i>Subprogram</i>	Tahapan yang menjalankan subprogram
	<i>Preparation</i>	Menetapkan nilai awal

Sumber: Pratiwi, 2020

2.11 PHP

PHP: Hypertext Preprocessor, adalah bahasa pemrograman yang digunakan dalam cakupan yang luas untuk pengelolaan, pembuatan, dan pengembangan situs web serta seringkali digunakan berbarengan dengan HTML. Ketika membuat halaman web, sebenarnya PHP bukanlah bahasa pemrograman yang wajib digunakan. Meskipun kita bisa membuat situs web hanya dengan HTML, yang dikenal sebagai website statis, dimana konten dan halaman bersifat tetap atau tidak berubah. Namun dengan PHP memungkinkan pembuatan halaman web yang lebih fleksibel dan dapat disesuaikan. Website dinamis yang dibangun dengan PHP dapat menyimpan data dalam database dan menampilkan konten yang berubah sesuai dengan input dari pengguna. (Oetomo & Mahargiano, 2020).

2.12 MySQL

MySQL adalah perangkat lunak yang termasuk dalam kategori DBMS (*Database Management System*). Sebagai DBMS, MySQL memiliki beberapa fitur, antara lain (Kadir, 2019):

1. Multiplatform

MySQL dapat dioperasikan pada berbagai *platform* seperti *Windows*, *Linux*, *Unix* dan lainnya.

2. Andal, Cepat, dan Mudah Digunakan

MySQL dikenal sebagai *database server* yang handal, mampu menangani *database* yang besar dengan kecepatan yang tinggi, serta menyediakan banyak fungsi untuk mengakses *database*, sekaligus mudah digunakan.

3. Jaminan Keamanan Akses

MySQL menawarkan fitur pengamanan *database* dengan berbagai kriteria akses. Misalnya, memungkinkan pengaturan pengguna tertentu untuk mengakses data yang bersifat pribadi.

4. Dukungan SQL

MySQL mendukung perintah SQL (*Structured Query Language*) yang merupakan standar dalam pengaksesan *database* relasional. Pengetahuan SQL akan mempermudah untuk menggunakan MySQL.

2.13 Riset Terkait

Ada beberapa penelitian berkaitan dengan klasifikasi menggunakan metode Single Exponential Smoothing, diantaranya adalah:

Table 2.5 Riset Terkait

No.	Penulis	Judul Penelitian	Hasil Penelitian
1.	Dani Anggoro dan Wulandari (2019)	<i>Recasting Demand Dengan Metode Single Exponential Smoothing Untuk Analisa Jumlah Penjualan Obat Ternak</i>	Penelitian ini menggunakan metode <i>Single Exponential Smoothing</i> dengan nilai α sebesar 0,4, nilai aktual sebesar 8125, nilai prediksi sebesar 7814, dan nilai MAD error sebesar 78 sehingga menghasilkan nilai akurasi sebesar 96% dari nilai data sebenarnya. Dapat disimpulkan bahwa tingkat kesalahan pemulusan eksponensial sederhana adalah 4%.
2.	Muhamad Taufik Ali dan Alfa Bintang (2022)	Pengendali Persediaan Barang Menggunakan Metode Single Exponential Smoothing untuk Peramalan Penjualan	Penelitian menggunakan <i>Single Exponential Smoothing</i> menghasilkan peramalan 132 unit induk bulan Januari 2022 dengan nilai presisi error sebesar 9% (akurasi tinggi) dengan menggunakan nilai α (α) tertimbang sebesar 0,3.
3.	Gaustama Putra dan Ari Rasyid Maulud (2020)	Peramalan Kebutuhan Batubara Menggunakan Metode	Berdasarkan hasil prediksi PT dan tingkat kesalahan. Solusi Bagun Andalas menggunakan metode pemulusan eksponensial sederhana $\alpha = 0,1$ (untuk unit tungku), $\alpha = 0,5$ (untuk

No.	Penulis	Judul Penelitian	Hasil Penelitian
		<p><i>Single Exponential Smoothing</i> di PT. Solusi Bangun Andalas</p>	<p>unit pembangkit listrik). Tingkat kegagalan MAD unit oven sebesar 2286,21, MSE sebesar 7.850.751,46, dan MAPE sebesar 26,88%. Sedangkan tingkat kegagalan MAD unit daya sebesar 2367,05, MSE sebesar 9.001.707,06, dan MAPE sebesar 18,35%. Hasil prakiraan periode ke-13 adalah blok tungku sebanyak 10.057,49 ton dan blok pembangkit listrik sebanyak 14.265 ton.</p>
4.	<p>Juniko Dwiki Saputro dan Setyawan Wibisono (2021)</p>	<p>Peramalan Dan Perengkingan Penjualan Produk <i>Furniture</i> Menggunakan Metode <i>Single Exponential Smoothing</i> Dan SAW</p>	<p>Berdasarkan hasil penelitian dapat disimpulkan bahwa metode SAW cocok untuk mengevaluasi produk furnitur karena memberikan hasil urutan penjualan yang terbaik. Setelah melakukan pemeringkatan produk furnitur, kami juga membuat prediksi kinerja penjualan tahun depan. Peramalan dilakukan dengan menggunakan metode <i>Single Exponential Smoothing</i>.</p>
5.	<p>Herman Santoso Pakpahan, Yuniarta</p>	<p>Prediksi Jumlah Penduduk Miskin Kalimantan</p>	<p>Berdasarkan hasil prediksi yang diperoleh, Kota Kutai Kartanegara menjadi kota penyumbang kemiskinan terbesar di Provinsi Kalimantan Timur.</p>

No.	Penulis	Judul Penelitian	Hasil Penelitian
	Basani dan Rahmawati Rina Hariani (2020)	Timur Menggunakan <i>Single</i> dan <i>Double Exponential Smoothing</i>	56.563 orang menggunakan metode <i>Single Exponential Smoothing</i> , 57.612 orang menggunakan metode <i>Double Exponential Smoothing</i> dengan Brown, dan 56.486 orang menggunakan metode <i>Double Exponential Smoothing</i> dengan Holt. Dari hasil uji perbandingan metode dengan menggunakan nilai MAPE, metode penghitungan data jumlah penduduk miskin di Kalimantan Timur yang paling akurat adalah “metode <i>Single Exponential Smoothing</i> ” dan “metode <i>Double Exponential Smoothing</i> ” dari Holt. Pengalaman data aktual meningkat dan menurun secara acak, dan terdapat juga tren dari data aktual untuk suatu kota atau kabupaten.
6.	Maysofa, Lidia Syaliman, Khairul Umam Sapriadi (2023)	Implementasi Forecasting Pada Penjualan Inaura Hair Care Dengan Metode <i>Single Exponential Smoothing</i>	Setelah dilakukan pengujian, dapat disimpulkan bahwa metode <i>Single Exponential Smoothing</i> diterapkan dengan baik dan nilai α adalah 0,2. Kinerja yang dihasilkan berada pada kategori “kemampuan prediksi baik” dengan nilai MAPE sebesar 0,04, nilai MAE sebesar 21, dan MSE sebesar 432.

No.	Penulis	Judul Penelitian	Hasil Penelitian
7.	Rika Safitri (2019)	Penerapan Metode <i>Single Exponential</i> Untuk Peramalan Volume Penjualan Minuman Kemasan (Studi Kasus: PT Coca Cola Amatil Indonesia Medan)	Penelitian yang dilakukan dengan metode <i>Single Exponential Smoothing</i> menunjukkan bahwa nilai <i>Mean Square Error</i> (MSE) terendah diperoleh dengan <i>Alpha</i> 0,2, yaitu sebesar 5.343.328. Ini mengindikasikan bahwa metode terbaik untuk meramalkan volume penjualan PT. Coca Cola Amatil Indonesia adalah dengan menggunakan <i>Alpha</i> 0,2. Oleh karena itu, prediksi volume penjualan untuk tahun 2017 diperkirakan mencapai 11.688.380.
8.	Niken Chaerunnisa dan Ade Momon (2021)	Perbandingan Metode <i>Single Exponential Smoothing</i> Dan <i>Moving Average</i> Pada Peramalan Penjualan Produk Minyak Goreng Di Pt Tunas Baru Lampung (2021)	Dengan menerapkan bobot 0,1, 0,3, 0,4, 0,5, 0,6, 0,7, dan 0,8 dalam metode <i>Single Exponential Smoothing</i> , diperoleh hasil bahwa untuk bobot 0,9 atau $\alpha = 0,8$, nilai MSE mencapai 250.570.764,80, MAD sebesar 12.922,32, dan MAPE sebesar 33,55. Sementara itu, dengan menggunakan pergerakan $n=3$ pada metode <i>Moving Average</i> , akurasi yang didapat adalah MSE sebesar 438.980.942,75, MAD sebesar 18.142,14, dan MAPE sebesar 41,37. Setelah membandingkan kedua metode tersebut, dapat disimpulkan bahwa metode <i>Single Exponential</i>

No.	Penulis	Judul Penelitian	Hasil Penelitian
			Smoothing merupakan metode terbaik untuk meramalkan penjualan Minyak Goreng Rose Brand 1 L.
9.	Rohmad Atkha dan Rusdah (2019)	Penerapan Metode <i>Single Exponential Smoothing</i> Untuk Memprediksi Jumlah Penjualan Bulanan Pada <i>Ranch Market Pesanggrahan</i>	Berdasarkan penelitian yang dilakukan di Ranch Market Pesanggrahan, dapat disimpulkan bahwa model <i>Single Exponential Smoothing</i> menghasilkan peramalan penjualan untuk bulan Desember 2017 sebesar 26 item untuk Kecap Manis Merk Bango 620 ml. Nilai kesalahan yang diperoleh dari pengujian model tersebut adalah MAD sebesar 6,18, MAPE sebesar 24,78%, dan MSE sebesar 52,44.
10.	Nuryani, Ely Rudianto Budiman, Ramdani Lazuardi dan Eric (2022)	Peramalan Persediaan Obat Menggunakan Metode <i>Single Exponential Smoothing</i>	Hasil penelitian mengenai sistem peramalan persediaan obat di Toko Aqilah Herbal menunjukkan bahwa sistem yang dikembangkan mampu melakukan peramalan untuk satu periode mendatang. Sistem ini juga berhasil menentukan nilai <i>Alpha</i> dengan tingkat kesalahan terendah, sehingga hasil peramalan persediaan obat dianggap valid dan dapat digunakan untuk pengadaan obat pada periode selanjutnya di Toko Aqilah Herbal.