

BAB II

LANDASAN TEORI

2.1. Landasan Teori

2.1.1. Prediksi

Prediksi merupakan suatu proses estimasi yang dilakukan secara terstruktur untuk memprediksi kejadian yang kemungkinan besar akan terjadi di masa depan berdasarkan data historis dan kondisi saat ini dengan tujuan mengurangi selisih antara hasil prediksi dan kenyataan. Prediksi tidak bertujuan menghasilkan hasil yang sepenuhnya tepat, melainkan memberikan estimasi yang mendekati kondisi sebenarnya yang mungkin terjadi. Menurut KBBI, prediksi merupakan hasil dari proses memperkirakan suatu nilai di masa depan berdasarkan informasi atau data dari masa lampau. Prediksi juga sering disebut sebagai ramalan atau perkiraan, yang digunakan sebagai input dalam proses perencanaan dan pengambilan keputusan [7].

Prediksi dapat dilakukan secara ilmiah maupun subjektif. Contohnya, prediksi cuaca dilakukan berdasarkan data dan pengamatan ilmiah, sedangkan prediksi pertandingan olahraga seringkali didasarkan pada opini subjektif. Seiring perkembangan zaman, penggunaan prediksi telah dimanfaatkan secara luas di berbagai bidang, termasuk bisnis, ekonomi, sosial, serta teknologi. Prediksi memiliki peran penting dalam mendukung proses pengambilan keputusan yang lebih tepat dan informatif, supaya langkah yang dilakukan menjadi efisien, efektif, dan mampu mengurangi potensi risiko di masa mendatang. Dalam studi ini, prediksi digunakan untuk meramalkan jumlah penduduk miskin berdasarkan data historis yang tersedia [8].

Deret waktu merupakan kumpulan data atau observasi yang dicatat secara berurutan dalam interval waktu tertentu, seperti data harian, bulanan, triwulanan, atau tahunan. Analisis deret waktu dipakai dalam mengkaji serta mengidentifikasi pola-pola atau kecenderungan dalam data historis yang dapat dimanfaatkan untuk memproyeksikan kondisi atau nilai di masa mendatang. Pendekatan ini banyak digunakan dalam berbagai bidang, seperti ekonomi, cuaca, kesehatan, dan

demografi, karena mampu memberikan gambaran tren yang berkelanjutan dari waktu ke waktu. Beberapa komponen utama dalam data deret waktu meliputi:

a. *Trend* (tren)

Tren adalah pola perubahan jangka panjang dalam data deret waktu yang menunjukkan kecenderungan meningkat atau menurun secara konsisten dari waktu ke waktu. Misalnya, jumlah penduduk yang terus bertambah setiap tahun menunjukkan adanya tren naik. Sebaliknya, jika suatu data menunjukkan penurunan secara berkelanjutan, maka itu disebut tren turun. Komponen tren dapat membantu melihat arah umum dari data dalam periode yang panjang, terlepas dari fluktuasi musiman atau gangguan acak.

b. *Seasonality* (musiman)

Musiman adalah pola yang berulang secara sistematis dalam periode waktu tertentu, biasanya dalam satu tahun. Pola ini dipengaruhi oleh faktor musiman seperti cuaca, hari libur, atau kebiasaan masyarakat. Contohnya adalah peningkatan konsumsi makanan menjelang hari raya atau peningkatan penjualan payung saat musim hujan. Komponen musiman bersifat tetap dan dapat diprediksi karena terjadi dalam interval waktu yang konsisten.

c. *Cyclic* (siklus)

Siklus adalah pola fluktuasi yang terjadi dalam jangka waktu lebih panjang dibandingkan pola musiman, dan tidak selalu terjadi secara teratur. Pola siklus sering kali berkaitan dengan kondisi ekonomi, seperti siklus bisnis yang mengalami fase ekspansi, puncak, kontraksi, dan resesi. Karena tidak terikat pada waktu yang tetap, komponen siklus lebih sulit diprediksi dan biasanya memerlukan analisis ekonomi makro untuk memahaminya.

d. *Irregular* (acak)

Komponen acak adalah variasi atau perubahan dalam data yang bersifat tidak teratur dan tidak dapat diprediksi. Faktor ini muncul akibat kejadian-kejadian luar biasa yang tidak terduga, seperti bencana alam, pandemi, krisis politik, atau peristiwa lain yang tidak memiliki pola historis. Karena bersifat tidak beraturan, komponen ini biasanya tidak dimasukkan dalam peramalan jangka panjang, tetapi tetap penting untuk dipertimbangkan sebagai bagian dari variasi data.

2.1.2. Kemiskinan

Kemiskinan merupakan suatu keadaan ketika individu atau sekelompok orang tidak memiliki kemampuan untuk memenuhi kebutuhan pokok yang diperlukan guna menjalani kehidupan yang layak. Kebutuhan pokok tersebut mencakup konsumsi pangan, sandang, tempat tinggal yang memadai, akses pendidikan, dan layanan kesehatan. Masalah kemiskinan bukan semata-mata disebabkan oleh rendahnya pendapatan, tetapi juga karena terbatasnya akses terhadap sumber daya serta pelayanan yang mendukung kesejahteraan hidup. Berdasarkan definisi dari BPS, penduduk miskin adalah mereka yang mempunyai rata-rata pengeluaran per kapita per bulan lebih rendah dari garis kemiskinan. Garis kemiskinan ditetapkan berdasarkan jumlah minimal pengeluaran yang diperlukan untuk memenuhi kebutuhan makanan dan kebutuhan selain makanan seperti hunian, pendidikan, serta transportasi. Oleh karena itu, seseorang diklasifikasikan sebagai miskin apabila tidak mampu mencukupi standar minimum pengeluaran untuk hidup secara layak [9].

Lebih lanjut, Perserikatan Bangsa-Bangsa (PBB) menyatakan bahwa kemiskinan merupakan kondisi yang bersifat multidimensi. Artinya, kemiskinan tidak semata-mata diukur berdasarkan tingkat pendapatan, melainkan juga mencakup keterbatasan dalam mengakses layanan dasar seperti air bersih, sanitasi yang memadai, pendidikan, layanan kesehatan, serta partisipasi dalam kegiatan sosial dan politik. Pandangan ini menegaskan bahwa kemiskinan memiliki sifat yang kompleks dan tidak dapat direpresentasikan hanya melalui satu ukuran tunggal [10].

Dampak dari kemiskinan dirasakan secara luas, tidak hanya pada aspek ekonomi, tetapi juga pada pembangunan manusia secara keseluruhan. Tingkat pendidikan yang rendah, akses kesehatan yang minim, serta kesempatan kerja yang sempit umumnya dialami oleh masyarakat yang berada dalam kondisi kemiskinan. Akibat dari situasi ini dapat berdampak pada menurunnya mutu sumber daya manusia di daerah tertentu, memperlambat pertumbuhan ekonomi, serta memperbesar kesenjangan sosial. Di Kota Tegal, masalah kemiskinan masih

menjadi perhatian utama pemerintah daerah. Berbagai program penanggulangan kemiskinan telah dilakukan, seperti bantuan sosial, pelatihan keterampilan, dan pemberdayaan ekonomi masyarakat.

2.1.3. Metode *Double Moving Average* (DMA)

Metode *Double Moving Average* merupakan salah satu teknik peramalan dalam analisis deret waktu yang digunakan untuk memprediksi nilai di masa mendatang berdasarkan data historis yang tersedia. DMA merupakan pengembangan dari metode *Moving Average* (MA) biasa, yang bertujuan untuk mengurangi fluktuasi data agar pola tren menjadi lebih jelas. Secara umum, metode DMA bekerja dengan melakukan proses perataan (*smoothing*) sebanyak dua kali. Tahap awal dilakukan dengan menghitung rata-rata dari beberapa periode data terdahulu (*Moving Average* pertama), lalu hasilnya dihitung kembali rata-ratanya untuk memperoleh *Moving Average* kedua. Hasil dari dua perataan ini digunakan untuk memperkirakan nilai pada periode selanjutnya [11].

Metode *Double Moving Average* merupakan pendekatan yang sesuai untuk diterapkan dalam memprediksi data deret waktu yang memiliki pola tren linier dan tidak menunjukkan pola musiman (*seasonality*) yang signifikan. Keunggulan dari metode ini adalah terletak pada kesederhanaannya dalam penerapan serta kemampuannya untuk mengurangi gangguan atau *noise* yang mungkin terdapat dalam data historis. Dengan demikian, metode ini membantu menghasilkan estimasi yang lebih halus dan akurat terhadap nilai di masa depan. Tahapan metode DMA terdiri dari sejumlah langkah, yaitu sebagai berikut:

- 1) Menghitung nilai *moving average* pertama

$$S'_t = \frac{x_t + x_{t-1} + x_{t-2} + \dots + x_{t-k-1}}{k} \quad (1)$$

- 2) Menghitung nilai *double moving average*

$$S''_t = \frac{S_t + S_{t-1} + S_{t-2} + \dots + S_{t-k-1}}{k} \quad (2)$$

- 3) Menghitung komponen a_t

$$a_t = 2 S'_t - S''_t \quad (3)$$

- 4) Menghitung komponen b_t

$$b_t = \frac{2}{k-1} (S'_t - S''_t) \quad (4)$$

5) Menghitung peramalan untuk periode mendatang

$$f_{t+m} = a_t + b_t m \quad (5)$$

Keterangan:

- x_t : nilai aktual pada periode t
- S'_t : *moving average* pertama periode t
- S''_t : *double moving average* periode t
- a_t : intersepsi atau konstan pada periode t
- b_t : nilai *tren* pada periode t
- f_{t+m} : peramalan pada periode t+1
- k : periode perataan (ordo)
- m : jumlah periode yang akan diprediksi

Metode *Double Moving Average* memiliki sejumlah kelebihan yang menjadikannya banyak digunakan dalam analisis deret waktu. Kelebihan utama dari metode ini adalah kesederhanaannya dalam penerapan, tidak memerlukan parameter yang kompleks, serta kemampuannya dalam menghaluskan data dan mengurangi fluktuasi acak sehingga tren dapat terlihat lebih jelas. DMA juga cocok digunakan ketika data menunjukkan pola tren linier dan tidak mengandung unsur musiman. Namun, kekurangannya terletak pada penentuan ordo yang belum baku dan kecenderungannya hanya menggunakan satu variabel historis, sehingga kurang efektif untuk data yang kompleks atau dipengaruhi oleh faktor eksternal. Oleh karena itu, penggunaannya perlu disesuaikan dengan karakteristik data yang dianalisis [12].

2.1.4. Metode *Double Exponential Smoothing* (DES)

Metode *Double Exponential Smoothing* adalah salah satu pendekatan peramalan *time series* yang dikembangkan oleh C. C. Holt pada tahun 1958. Metode DES menggunakan data terkini secara terus-menerus untuk memperbarui hasil prediksi, dengan menerapkan parameter pemulusan (α) yang berada dalam rentang

antara 0 hingga 1. Karena proses pemulusan dilakukan dalam dua tahap, maka teknik ini dikenal dengan istilah *double exponential smoothing* [13].

Dalam praktiknya, metode DES terbagi menjadi 2 tipe, yaitu model dengan 1 parameter yang dikenal sebagai *Brown's Linear Method*, serta model dengan 2 parameter yang disebut *Holt's Method*. Dalam studi ini, pendekatan yang diterapkan adalah metode DES dengan 1 parameter atau *Brown's Linear Method*, yang secara otomatis mengakomodasi komponen tren melalui dua tahap pemulusan tanpa perlu memisahkan level dan tren secara langsung. Metode DES tepat untuk menganalisis data *time series* yang mempunyai kecenderungan pola tren *linier*. Langkah-langkah penerapan metode DES akan diuraikan sebagai berikut:

- 1) Menghitung nilai *Exponential Smoothing*

$$S'_t = \alpha x_t + (1 - \alpha)S'_{t-1} \quad (6)$$

- 2) Menghitung nilai *Double Exponential Smoothing*

$$S''_t = \alpha S'_t + (1 - \alpha)S''_{t-1} \quad (7)$$

- 3) Menghitung nilai konstan

$$a_t = 2 S'_t - S''_t \quad (8)$$

- 4) Menghitung nilai koefisien *tren*

$$b_t = \frac{\alpha}{1 - \alpha} (S'_t - S''_t) \quad (9)$$

- 5) Menghitung peramalan untuk periode mendatang

$$f_{t+m} = a_t + b_t m \quad (10)$$

Keterangan:

S'_t : *exponential smoothing* periode t

S''_t : *double exponential smoothing* periode t

X_t : nilai data aktual pada periode t

a_t : nilai konstan

b_t : koefisien *tren*

f_{t+m} : nilai peramalan untuk m periode ke depan

α : parameter alpha

m : jumlah periode yang akan diprediksi

Metode DES mempunyai beberapa kelebihan, antara lain kemampuannya dalam menangkap tren data secara akurat, bahkan ketika jumlah data terbatas. Metode ini juga hanya memerlukan satu atau dua parameter, sehingga cukup sederhana dan mudah diimplementasikan. Selain itu, pendekatan DES lebih menekankan data masa kini, menjadikannya lebih adaptif terhadap dinamika tren yang berubah. Namun demikian, DES juga memiliki kekurangan, seperti sensitivitas terhadap pemilihan parameter smoothing, yang jika tidak tepat dapat menghasilkan prediksi yang kurang akurat. Selain itu, metode ini tidak dirancang untuk menangani data yang memiliki unsur musiman dan cenderung mengasumsikan bahwa tren terus berlanjut. Oleh karena itu, dalam penggunaannya, DES harus disesuaikan dengan karakteristik data dan tujuan peramalan yang diinginkan [14].

2.1.5. Python

Python adalah bahasa pemrograman interpretatif yang memiliki berbagai fungsi dan dikembangkan dengan penekanan pada keterbacaan serta kemudahan dalam memahami sintaks. Bahasa ini dirancang untuk membantu programmer dalam menyusun program secara efisien, mempercepat proses pengembangan, dan memiliki tingkat kompatibilitas tinggi terhadap berbagai sistem [15]. Python dilengkapi dengan berbagai *library* yang mendukung kegiatan analisis data secara efektif, termasuk *pandas*, *numpy*, dan *matplotlib* sebagai beberapa contohnya. Python banyak digunakan dalam bidang akademik dan industri karena kemampuannya dalam mengolah data secara efisien, mendukung pengembangan kecerdasan buatan, dan integrasinya yang mudah dengan berbagai sistem dan platform, menjadikannya pilihan utama dalam pengembangan aplikasi berbasis data dan penelitian ilmiah.

a) Teori Bahasa Pemrograman dan Desain Komputer

Bahasa pemrograman adalah sistem notasi formal yang digunakan untuk menuliskan instruksi atau algoritma agar dapat diproses oleh komputer. Fungsinya

sebagai jembatan antara manusia dan mesin memungkinkan pengguna memberikan perintah yang dapat dijalankan oleh komputer. Python dirancang untuk meningkatkan produktivitas pengembang dengan sintaks yang sederhana, jelas, dan mudah dipahami. Salah satu prinsip utamanya adalah keterbacaan kode (*code readability*), yaitu kemampuan kode untuk dipahami secara cepat oleh manusia. Dengan desain penulisan yang konsisten melalui indentasi, Python meminimalkan kesalahan dan mendukung pengembangan perangkat lunak secara efisien. Dalam hal desain komputer modern, Python menyederhanakan interaksi antara manusia dan mesin, sehingga mudah digunakan oleh pengguna dari berbagai latar belakang, termasuk non-programmer, dalam pengembangan aplikasi maupun penelitian [16].

b) Paradigma Pemrograman

Python mendukung berbagai paradigma pemrograman yang memungkinkan fleksibilitas dalam menyusun logika program. Paradigma pertama adalah pemrograman prosedural, di mana instruksi ditulis dalam bentuk langkah-langkah atau prosedur yang dieksekusi secara berurutan. Kedua adalah pemrograman berorientasi objek (*object-oriented programming*), di mana data dan fungsi dikemas dalam objek untuk memudahkan pengelolaan dan pemeliharaan kode. Selain itu, Python juga mendukung pemrograman fungsional (*functional programming*), yang menekankan pada penggunaan fungsi-fungsi murni tanpa efek samping. Kemampuan Python untuk menggabungkan berbagai paradigma ini membuatnya sangat fleksibel dan cocok untuk berbagai jenis proyek.

c) Teori Struktur Data dan Algoritma

Struktur data dan algoritma merupakan dua komponen utama dalam pengolahan data. Struktur data menyangkut cara menyimpan dan mengatur data dalam memori, sedangkan algoritma berkaitan dengan langkah-langkah sistematis untuk memproses data tersebut. Python menyediakan berbagai struktur data bawaan seperti *list*, *tuple*, *set*, dan *dictionary*. Selain itu, Python juga memiliki pustaka seperti *collections* dan *heapq* yang mendukung manipulasi struktur data tingkat lanjut. Untuk algoritma, Python memungkinkan implementasi berbagai metode

seperti pencarian (*search*), pengurutan (*sorting*), dan optimasi. Ketersediaan struktur data dan algoritma yang lengkap menjadikan Python alat yang kuat dalam pengolahan data, termasuk dalam peramalan.

d) Teori Komunitas dan Ekosistem *Open Source*

Salah satu kekuatan utama Python terletak pada komunitas globalnya yang besar dan aktif. Python bersifat *open source*, artinya siapa saja dapat mengakses, menggunakan, dan mengembangkan bahasa ini secara bebas. Komunitas Python secara aktif berkontribusi dalam pengembangan pustaka baru, peningkatan performa, dokumentasi, serta forum diskusi daring. Ekosistem *open source* ini menciptakan lingkungan kolaboratif yang sangat mendukung, sehingga pengguna Python dapat memanfaatkan berbagai pustaka dan proyek yang telah dikembangkan sebelumnya tanpa harus membangun dari awal. Hal ini mempercepat proses penelitian dan pengembangan di berbagai bidang, termasuk pendidikan, industri, dan riset ilmiah.

e) Komputasi Ilmiah Data *Science*

Python telah menjadi bahasa utama dalam bidang data science dan komputasi ilmiah karena kemampuannya dalam mengolah, menganalisis, dan memvisualisasikan data dalam skala besar. Dengan pustaka seperti *NumPy* untuk komputasi numerik, *Pandas* untuk manipulasi data, *Matplotlib* dan *Seaborn* untuk visualisasi grafik, serta *SciPy* untuk perhitungan ilmiah, Python menawarkan solusi lengkap untuk kebutuhan analisis data. Selain itu, dalam bidang machine learning, pustaka seperti *Scikit-learn*, *TensorFlow*, dan *PyTorch* memungkinkan pengembangan model prediktif dan klasifikasi secara efisien. Kemampuan Python dalam komputasi ilmiah sangat mendukung proses analisis data dalam penelitian, termasuk dalam peramalan jumlah penduduk miskin seperti yang dilakukan dalam penelitian ini.

2.1.6. Mean Absolute Percentage Error (MAPE)

MAPE dikenal sebagai salah satu indikator yang umum dimanfaatkan untuk menilai tingkat akurasi dari suatu model peramalan. Indikator MAPE digunakan untuk menunjukkan sejauh mana perbedaan antara nilai prediksi dan nilai asli dalam bentuk persentase rata-rata [17]. MAPE sangat berguna karena hasilnya berupa persentase, sehingga memudahkan interpretasi dalam mengevaluasi keakuratan model. Semakin kecil nilai MAPE, semakin besar pula tingkat ketepatan dari model peramalan yang digunakan. Perhitungan MAPE dapat dilakukan dengan menggunakan rumus berikut:

$$MAPE = \left(\frac{1}{n}\right) \sum_{t=1}^n \frac{|X_t - F_t|}{x_t} \times 100 \quad (11)$$

Keterangan:

- X_t : nilai aktual pada periode t
- F_t : nilai ramalan pada periode t
- n : banyaknya periode waktu

a) Teori Kesalahan (*Error Theory*) dan Evaluasi Model Prediksi

Dalam evaluasi model prediksi, teori kesalahan berfungsi untuk mengukur seberapa besar penyimpangan antara nilai yang diprediksi dengan nilai sebenarnya. Tujuannya adalah untuk menilai kualitas dan keandalan dari suatu model. Salah satu metrik yang banyak digunakan adalah MAPE karena bersifat intuitif dan memberikan informasi dalam bentuk persen, sehingga mudah dipahami oleh pengguna non-teknis. Dengan mengevaluasi kesalahan, peneliti atau pembuat keputusan dapat mengetahui seberapa dekat hasil prediksi dengan kenyataan dan menentukan apakah model yang digunakan dapat diterapkan secara praktis.

b) Teori Kesalahan Relatif

MAPE termasuk dalam kategori kesalahan relatif karena perhitungan kesalahannya dibandingkan dengan nilai aktual. Berbeda dengan MSE atau MAE yang hanya melihat besarnya selisih dalam satuan asli, MAPE memperhitungkan ukuran kesalahan terhadap nilai aktualnya. Hal ini memungkinkan evaluasi kinerja

model dalam berbagai skala data yang berbeda. Sebagai contoh, kesalahan sebesar 100 pada nilai aktual 1.000 akan memberikan persentase kesalahan 10%, tetapi akan menjadi 50% jika nilai aktual hanya 200.

c) Asumsi dan Keterlambatan

Dalam penggunaannya, MAPE memiliki beberapa asumsi dan keterlambatan. Salah satu kelemahan utamanya adalah ketidaktepatan saat nilai aktual mendekati nol, karena akan menghasilkan nilai kesalahan yang sangat besar atau bahkan tak terhingga. Selain itu, MAPE cenderung lebih berat menghukum kesalahan prediksi yang melebihi nilai aktual (*overforecasting*) dibandingkan kesalahan yang berada di bawah nilai aktual (*underforecasting*). Oleh karena itu, MAPE paling cocok digunakan ketika nilai aktual tidak mengandung angka nol atau sangat kecil, serta ketika kesalahan proporsional menjadi perhatian utama dalam evaluasi model.

d) Alternatif dan Pertimbangan Lain

Meskipun MAPE populer, ada beberapa alternatif yang bisa dipertimbangkan tergantung pada karakteristik data dan tujuan analisis. Misalnya, *Symmetric Mean Absolute Percentage Error* digunakan untuk mengatasi masalah pembagian dengan nol, sedangkan *Mean Absolute Scaled Error* (MASE) berguna untuk membandingkan akurasi antara beberapa model yang berbeda. Dalam praktiknya, pemilihan metrik evaluasi harus disesuaikan dengan peramalan yang dilakukan, karakteristik data, dan kebutuhan interpretasi hasil oleh pengambil kebijakan. Oleh karena itu, penggunaan MAPE sebaiknya dilakukan bersama dengan pemahaman terhadap situasi dan keterbatasannya.

MAPE memiliki beberapa kelebihan yang menjadikannya populer dalam evaluasi model peramalan. Salah satunya adalah hasil evaluasi yang disajikan dalam bentuk persentase, sehingga mudah dipahami dan dapat dibandingkan antar model meskipun menggunakan satuan data yang berbeda. MAPE juga memberikan gambaran sejauh mana kesalahan prediksi terhadap nilai aktual secara proporsional.

Namun, MAPE juga memiliki kekurangan, terutama ketika nilai aktual mendekati nol, karena dapat menghasilkan nilai kesalahan yang sangat besar atau tidak terhingga. Selain itu, MAPE cenderung memberikan penalti lebih besar pada kesalahan prediksi yang melebihi nilai aktual (*overforecasting*) dibandingkan kesalahan yang lebih kecil dari nilai aktual (*underforecasting*). Oleh karena itu, meskipun MAPE sangat berguna, penggunaannya harus disesuaikan dengan sifat data dan kondisi peramalan yang dianalisis.

2.2. Penelitian Terdahulu

Penelitian ini merujuk pada sejumlah kajian sebelumnya untuk menghimpun teori-teori yang mendukung topik yang diteliti, sebagaimana dijelaskan berikut ini:

1. Penelitian yang dilakukan oleh F. Kusuma, M. Ahsan, dan S. Syahminan tentang penggunaan metode *Single Moving Average* (SMA) dan *Double Moving Average* (DMA) untuk memprediksi jumlah penduduk miskin di Indonesia berdasarkan data dari Badan Pusat Statistik (BPS) periode 2007-2020. Hasil penelitian menunjukkan bahwa metode ini efektif untuk analisis data historis dengan tingkat akurasi yang tinggi, dibuktikan dengan nilai MAPE sebesar 3,47%, yang menunjukkan peramalan sangat baik. Sistem yang dikembangkan berbasis PHP memungkinkan pengguna untuk memprediksi jumlah penduduk miskin secara dinamis, memberikan manfaat bagi pemerintah dan pemangku kepentingan lainnya dalam merancang kebijakan pengentasan kemiskinan secara lebih terukur [18].
2. Penelitian yang dilakukan oleh Z. Ngabidin, A. Sanwidi, dan E. R. Arini yang menggunakan metode *Double Exponential Smoothing* (DES) *Brown* untuk meramalkan jumlah penduduk miskin di Kabupaten Blitar berdasarkan data 19 tahun terakhir. Penelitian ini menemukan bahwa parameter alpha terbaik adalah 0.7, dengan hasil error terendah: MAD 4.95, MSE 49.47, dan MAPE 3.79. Prediksi untuk periode 2023-2027 menunjukkan tren penurunan jumlah penduduk miskin dari 100,07 ribu pada tahun 2023 menjadi 85,86 ribu pada tahun 2027. Penelitian ini memberikan rekomendasi kebijakan berbasis data

yang diharapkan dapat membantu pemerintah daerah dalam meningkatkan kesejahteraan masyarakat. Hal ini menggarisbawahi akurasi metode DES dalam menangkap tren linier untuk peramalan data sosial [19].

3. Penelitian yang dilakukan oleh N. Rahmansyah, S. A. Lusinia, R. L. Gema, dan S. Safira yang mengkaji penerapan metode *Double Moving Average* (DMA) untuk meramalkan garis kemiskinan di Provinsi Sumatera Barat berdasarkan pendekatan kebutuhan dasar. Penelitian ini menggunakan data deret waktu pengeluaran per kapita bulanan masyarakat dari tahun 2012 hingga 2020, baik di wilayah perkotaan maupun perdesaan. Dengan mengidentifikasi pola tren linier dalam data, digunakan model MA(3×3) untuk menghasilkan peramalan. Hasilnya menunjukkan bahwa metode DMA cukup efektif dalam mengikuti pola data aktual garis kemiskinan, dengan hasil prediksi untuk tahun 2021 mencapai 603.046 untuk daerah perkotaan dan 560.287 untuk daerah perdesaan [20].
4. Penelitian yang dilakukan oleh S. Salsabilla Sururin, W. Sa'dun Akbar, E. Widodo, dan J. Statistika mengaplikasikan metode *Double Exponential Smoothing* (DES) untuk meramalkan garis kemiskinan di Provinsi Daerah Istimewa Yogyakarta (DIY) berdasarkan data Badan Pusat Statistik dari tahun 2004 hingga 2022. Penelitian ini menunjukkan bahwa data garis kemiskinan DIY memiliki pola tren meningkat secara signifikan tanpa adanya penurunan dari tahun ke tahun, sehingga metode DES dipilih sebagai pendekatan peramalan yang sesuai. Dengan menggunakan komputasi RStudio dan parameter smoothing optimal ($\alpha = 0,51$ dan $\beta = 0,59$), diperoleh nilai MAPE sebesar 1,87%, yang mengindikasikan bahwa model memiliki tingkat akurasi sangat tinggi. Hasil peramalan menunjukkan bahwa garis kemiskinan akan terus meningkat pada periode 2023 hingga 2027, dengan nilai prediksi berturut-turut yaitu 546.839, 576.758, 606.678, 636.598, dan 666.517. Penelitian ini menyimpulkan bahwa metode DES sangat efektif untuk memprediksi tren data sosial ekonomi seperti garis kemiskinan dan dapat digunakan sebagai dasar perencanaan kebijakan pengentasan kemiskinan yang lebih tepat sasaran di wilayah DIY [21].

5. Penelitian yang dilakukan oleh H. S. Pakpahan, Y. Basani, dan R. R. Hariani yang bertujuan untuk memprediksi jumlah penduduk miskin di Provinsi Kalimantan Timur dengan menggunakan metode *Single Exponential Smoothing* serta *Double Exponential Smoothing* dari *Brown* dan *Holt*. Penelitian ini menggunakan data deret waktu dari tahun 2010 hingga 2018 yang diperoleh dari BPS Kalimantan Timur, dan mengevaluasi akurasi model menggunakan indikator MAPE. Hasil penelitian ini menunjukkan bahwa untuk beberapa kabupaten/kota, metode SES memberikan hasil prediksi yang lebih akurat, sementara pada wilayah dengan pola tren yang lebih jelas, metode DES *Holt* maupun *Brown* lebih sesuai. Hasil terbaik secara keseluruhan menunjukkan bahwa metode *Single Exponential Smoothing* dan DES *Holt* dapat digunakan secara efektif untuk meramalkan data kemiskinan tergantung pada karakteristik data masing-masing wilayah [22].

Berdasarkan kajian dari penelitian sebelumnya, penelitian ini menghadirkan keterbaruan dengan menerapkan dan membandingkan dua metode peramalan klasik, yaitu DMA dan DES, secara khusus untuk memprediksi jumlah penduduk miskin di Kota Tegal, wilayah yang masih jarang menjadi fokus dalam studi peramalan kemiskinan. Penelitian ini menggunakan data selama 20 tahun terakhir, sehingga memberikan cakupan historis yang cukup panjang. Selain berfokus pada hasil prediksi, penelitian ini juga secara sistematis mengevaluasi tingkat akurasi kedua metode melalui nilai MAPE, sehingga dapat memberikan rekomendasi metode peramalan yang paling tepat bagi pemerintah daerah dalam merumuskan kebijakan pengentasan kemiskinan berbasis data lokal.