

BAB II

TINJAUAN PUSTAKA

2.1 Analisis Deret Waktu

Analisis deret waktu (time series analysis) adalah salah satu metode statistik yang digunakan untuk menganalisis data yang dikumpulkan secara berurutan berdasarkan waktu. Data dalam bentuk deret waktu biasanya tersusun secara kronologis, seperti data harian, bulanan, atau tahunan, sehingga memiliki keterkaitan antar periode waktu yang berdekatan. Berbeda dengan data biasa, data deret waktu memiliki karakteristik khusus berupa adanya ketergantungan nilai masa kini terhadap nilai di masa lalu, sehingga pendekatan analisis yang digunakan juga harus mampu menangkap pola temporal tersebut.

Secara umum, deret waktu dapat didefinisikan sebagai sekumpulan observasi yang dicatat secara berurutan dalam interval waktu tertentu. Analisis terhadap data ini bertujuan untuk mengidentifikasi pola, memahami struktur data, serta memprediksi nilai di masa mendatang. Analisis deret waktu tidak hanya digunakan untuk memahami pola historis suatu data, tetapi juga berperan penting dalam proses peramalan (forecasting) sebagai dasar pengambilan keputusan di berbagai bidang peramalan (forecasting) sebagai dasar pengambilan keputusan di berbagai bidang (Hyndman & Athanasopoulos, 2021).

2.2 Analisis Engagement Media

Analisis engagement dalam media merupakan suatu pendekatan yang digunakan untuk memahami tingkat keterlibatan audiens terhadap konten yang dipublikasikan, khususnya pada media digital seperti YouTube. Dalam perkembangan teknologi komunikasi saat ini, media tidak lagi hanya berperan sebagai penyampai informasi, tetapi juga sebagai ruang interaksi antara produsen konten dan audiens. Oleh karena itu, engagement menjadi indikator penting dalam menilai keberhasilan suatu media dalam menarik perhatian, mempertahankan minat, serta membangun hubungan jangka panjang dengan audiensnya.

Engagement merupakan tolak ukur yang digunakan untuk melihat tingkat keterlibatan penonton atau audiens pada suatu program di media sosial ((Amira K, 2021; dikutip dalam Fitri & Yutanti, 2024)). Secara umum, semakin tinggi tingkat engagement suatu konten, semakin besar peluang konten tersebut untuk menjangkau audiens yang lebih luas melalui sistem algoritma pada platform digital.

Hal ini sejalan dengan temuan pada penelitian mengenai strategi optimasi media sosial Lembaga Sensor Film Republik Indonesia (LSF RI), sebuah lembaga milik negara yang juga menjadikan data engagement sebagai tolak ukur keberhasilan penyampaian pesan dan kebermanfaatan suatu konten pada kanal YouTube-nya (Fitri & Yutanti, 2024). Penelitian tersebut secara spesifik menggunakan indikator penayangan, waktu tonton, rasio klik-tayang,

rata-rata durasi tonton, serta jumlah penonton kembali sebagai bagian dari data analytics untuk mengukur peningkatan engagement kontennya (Fitri & Yutanti, 2024), yang menunjukkan bahwa indikator-indikator kuantitatif semacam ini lazim digunakan dalam mengevaluasi performa konten pada platform YouTube. Hal ini diperkuat oleh penelitian (Wu et al., 2018) yang menganalisis lebih dari 5 juta video YouTube dan menemukan bahwa metrik seperti views, watch time, dan persentase durasi tontonan merupakan indikator utama yang paling relevan untuk mengukur tingkat engagement dan kualitas video dibandingkan metrik lain.

Perilaku audiens dalam mengonsumsi konten digital cenderung bersifat dinamis dan dipengaruhi oleh berbagai faktor, seperti tren yang sedang berkembang, preferensi individu, serta intensitas penggunaan media sosial. Dinamika semacam ini tercermin pula pada studi mengenai transisi generasi Milenial dan Generasi Z dari radio tradisional ke platform musik digital, yang menemukan bahwa aksesibilitas, personalisasi, dan fitur interaktif menjadi faktor utama yang mendorong pergeseran preferensi audiens terhadap suatu media (Sayyaf et al., 2025). Studi tersebut juga menegaskan bahwa media tradisional seperti radio perlu beradaptasi dengan teknologi digital agar tetap mampu mempertahankan audiensnya di tengah perubahan preferensi yang terus berlangsung.

Dengan kata lain, engagement tidak hanya dipengaruhi oleh isi konten, tetapi juga oleh bagaimana konten tersebut dirancang, dipublikasikan, didistribusikan, serta bagaimana audiens meresponsnya. Hal ini sejalan dengan

temuan bahwa keberhasilan distribusi konten media ditentukan oleh pemilihan saluran dan waktu publikasi yang tepat, segmentasi audiens, serta peran algoritma media sosial dalam mengarahkan visibilitas konten kepada pengguna (Khasanah & Artikel, 2024). Proses interaksi tersebut menunjukkan bahwa keberhasilan suatu konten digital merupakan hasil keterkaitan antara strategi penyajian konten, karakteristik platform, dan perilaku pengguna dalam mengonsumsi informasi.

Oleh karena itu, YouTube tidak hanya berfungsi sebagai media berbagi video, tetapi juga menjadi bagian dari ekosistem media digital yang membentuk pola konsumsi informasi, komunikasi, dan interaksi masyarakat secara luas. Kondisi tersebut diperkuat oleh penelitian (Lubis E R et al., 2026) yang menjelaskan bahwa YouTube telah berkembang menjadi infrastruktur sosial digital yang memengaruhi berbagai aspek kehidupan masyarakat Indonesia, mulai dari pendidikan, komunikasi, ekonomi kreatif, hingga pembentukan perilaku konsumsi media.

Penelitian ini menunjukkan bahwa kualitas konten, konsistensi publikasi, serta kesesuaian konten dengan preferensi audiens merupakan faktor utama yang dapat meningkatkan keterlibatan audiens secara signifikan. Hasil penelitian yang dilakukan oleh (Fikriyah et al., 2025) menunjukkan bahwa strategi produksi konten yang berorientasi pada preferensi audiens, didukung dengan konsistensi unggahan.

Dalam konteks analisis data, engagement dapat dikategorikan sebagai data deret waktu time series karena memiliki pola perubahan dari waktu ke

waktu. Pola tersebut umumnya terdiri dari tren dan musiman.

Salah satu aspek yang sangat penting dalam analisis ini adalah pola musiman (seasonality), yaitu pola berulang yang terjadi dalam periode tertentu. Pola musiman berbeda dengan tren, musiman adalah fluktuasi yang berulang secara teratur dalam periode tertentu, sedangkan tren adalah arah pergerakan data secara umum dalam jangka panjang. Pola musiman menjadi sangat krusial untuk dianalisis karena perilaku audiens tidak bersifat acak sepenuhnya, melainkan dipengaruhi oleh waktu dan momen tertentu, seperti hari libur, akhir pekan, atau tren yang sedang viral. Sebagai contoh, peningkatan jumlah penonton sering terjadi pada periode tertentu yang memiliki keterkaitan dengan aktivitas audiens. Jika pola musiman ini tidak diperhatikan, maka model analisis maupun peramalan akan menghasilkan prediksi yang kurang akurat.

Oleh karena itu, pemahaman terhadap pola musiman menjadi salah satu faktor kunci dalam meningkatkan akurasi analisis engagement. Selain itu, analisis musiman juga memiliki implikasi praktis dalam strategi pengelolaan media. Dengan mengetahui waktu-waktu tertentu ketika audiens lebih aktif, pengelola media dapat menentukan waktu publikasi konten yang lebih optimal sehingga peluang konten untuk memperoleh jumlah tayangan (views), serta interaksi dari pengguna menjadi lebih tinggi.

Strategi penentuan waktu publikasi merupakan salah satu faktor penting dalam manajemen media sosial karena algoritma platform digital cenderung memberikan exposure yang lebih besar terhadap konten yang

memperoleh interaksi tinggi pada saat awal dipublikasikan. Penelitian yang dilakukan oleh (Ghefira Sari Kholili & Yanti Susanti, 2026) menunjukkan bahwa waktu publikasi memiliki pengaruh yang signifikan terhadap engagement rate, di mana konten yang diunggah pada jam aktif audiens menghasilkan tingkat interaksi yang lebih tinggi dibandingkan konten yang dipublikasikan di luar jam aktif pengguna.

2.3 YouTube

YouTube merupakan salah satu platform berbagi video terbesar di dunia yang memungkinkan pengguna mengunggah, menonton, serta berinteraksi dengan berbagai konten secara digital. YouTube kini dikenal sebagai media informasi interaktif, karena penggunaannya dapat berperan sekaligus sebagai penonton dan pencipta konten (Chandra, 2009), menjadikannya media komunikasi, hiburan, dan edukasi yang berpengaruh besar terhadap pola konsumsi informasi masyarakat modern.

Di Indonesia, YouTube menjadi salah satu platform digital yang paling banyak digunakan, khususnya oleh generasi muda, karena menyediakan akses informasi, hiburan, pembelajaran, dan interaksi secara cepat dan mudah diakses kapan saja. Hal ini diperkuat oleh temuan bahwa YouTube berperan efektif sebagai media edukasi bagi Generasi Z, karena memungkinkan interaksi yang fleksibel dan memperkaya pengalaman belajar melalui konten yang informatif (Daraini & Masnawati, 2024).

Dalam penelitian ini, YouTube digunakan sebagai sumber data utama untuk menganalisis tingkat engagement audiens terhadap konten yang

dipublikasikan oleh RRI Pro 2 Malang. Data yang dianalisis berupa jumlah views atau jumlah penonton dari setiap video yang diunggah selama periode penelitian.

Menurut penelitian (Limarandani et al., 2025), pemanfaatan YouTube sebagai media pembelajaran memiliki pengaruh positif dan signifikan terhadap peningkatan minat serta motivasi audiens karena mampu menyajikan informasi secara menarik dan interaktif. Penelitian tersebut juga menjelaskan bahwa YouTube tidak hanya berfungsi sebagai media hiburan, tetapi juga sebagai media komunikasi digital yang mampu meningkatkan keterlibatan engagement pengguna. Selain itu, penelitian (Tri Ayu Mareta et al., 2025b) menjelaskan bahwa

YouTube memiliki peran penting sebagai media edukasi bagi Generasi Z karena menyediakan akses terhadap berbagai konten pembelajaran yang interaktif, fleksibel, dan mudah dipahami. Penelitian tersebut menegaskan bahwa karakteristik YouTube yang mampu menghadirkan video secara visual dan interaktif menjadikan platform ini efektif dalam meningkatkan perhatian serta partisipasi audiens terhadap suatu konten.

Menurut penelitian ini, jumlah views pada YouTube dapat digunakan sebagai indikator untuk mengetahui tingkat perhatian dan respons audiens terhadap suatu konten. Semakin tinggi jumlah views, maka semakin besar pula tingkat jangkauan dan interaksi audiens terhadap konten yang dipublikasikan. Oleh karena itu, data views menjadi salah satu komponen penting dalam mengukur perkembangan engagement pada kanal YouTube RRI Pro 2 Malang.

Sebagai platform digital yang bersifat dinamis, YouTube menghasilkan pola data yang cenderung berubah-ubah dari waktu ke waktu. Perubahan tersebut dipengaruhi oleh berbagai faktor, seperti tren konten yang sedang populer, waktu publikasi video, momentum tertentu, konsistensi unggahan, serta preferensi audiens yang terus berkembang. Kondisi ini menyebabkan data engagement memiliki karakteristik fluktuatif dan tidak stabil, sehingga pola kenaikan maupun penurunan jumlah penonton dapat terjadi secara signifikan dalam periode tertentu.

Karakteristik data yang dinamis tersebut menjadikan analisis deret waktu (time series) sebagai pendekatan yang relevan dalam penelitian ini. Melalui analisis deret waktu, pola historis pada data dapat dipelajari untuk mengetahui kecenderungan tren, musiman (seasonality), serta perubahan perilaku audiens dari waktu ke waktu. Oleh karena itu, diperlukan metode prediksi yang mampu menangkap pola fluktuatif tersebut secara akurat agar hasil analisis dapat memberikan gambaran yang lebih baik mengenai perkembangan engagement YouTube RRI Pro 2 Malang pada periode mendatang.

2.4 Metode Seasonal ARIMA (SARIMA)

Metode SARIMA (Seasonal Autoregressive Integrated Moving Average) merupakan salah satu metode peramalan deret waktu time series yang digunakan untuk menganalisis data yang memiliki pola tren dan musiman secara bersamaan. Metode ini merupakan pengembangan dari model ARIMA dengan tambahan komponen musiman (seasonal component), sehingga lebih

mampu menangani data yang mengalami pola berulang dalam periode tertentu, seperti bulanan, triwulanan, maupun tahunan.

Secara sederhana, SARIMA dapat dipahami sebagai metode yang mempelajari pola data masa lalu untuk memprediksi kemungkinan yang akan terjadi pada masa mendatang. Metode ini sangat cocok digunakan pada data yang mengalami kenaikan dan penurunan secara berulang dari waktu ke waktu. Oleh karena itu, SARIMA banyak digunakan dalam berbagai bidang.

Di bidang energi, SARIMA digunakan untuk peramalan permintaan daya listrik dan beban puncak (Eshragh et al., 2021), di bidang ekonomi, digunakan untuk memproyeksikan indeks saham, peredaran mata uang, dan pertumbuhan produk domestik bruto (da Costa et al., 2022), di bidang kesehatan, SARIMA dan variannya menjadi salah satu model utama dalam peramalan kasus dan kematian akibat wabah penyakit seperti COVID-19, bahkan terbukti mengungguli model pembandingan dari sisi akurasi (Brasoveanu et al., 2020) dan sementara di bidang cuaca, SARIMA digunakan secara luas sebagai teknik peramalan suhu dan parameter meteorologi lain yang memiliki pola musiman (Saikia et al., 2025).

Penerapan yang luas ini menunjukkan fleksibilitas SARIMA dalam menangani data deret waktu dengan pola musiman, meskipun penerapannya pada data engagement media digital seperti platform video masih tergolong area penelitian yang relatif baru dan belum banyak dieksplorasi.

Keunggulan utama metode SARIMA terletak pada kemampuannya dalam membaca hubungan antar data historis sekaligus mengenali pola

musiman yang berulang secara teratur pada interval waktu tertentu, yang diidentifikasi melalui analisis ACF dan PACF sebagai alat untuk mendeteksi lonjakan signifikan pada lag-lag musiman.

Namun perlu dicatat bahwa kemampuan ini terbatas pada pola yang bersifat berulang dan periodik, sementara lonjakan data akibat fenomena viral pada dasarnya bersifat acak dan sulit diprediksi secara pasti. Karakteristik inilah yang menjelaskan mengapa pada data YouTube RRI Pro 2 Malang, SARIMA mampu menangkap pola musiman yang berulang dengan cukup baik, namun tetap menghasilkan tingkat kesalahan yang relatif tinggi ketika terdapat lonjakan ekstrem akibat video yang viral secara tiba-tiba.

Secara konsep, metode SARIMA bekerja dengan melihat hubungan antara data saat ini dengan data-data sebelumnya. Model ini menggabungkan tiga komponen utama, yaitu autoregressive (AR), integrated (I), dan moving average (MA), kemudian menambahkan komponen musiman (seasonal) agar mampu membaca pola pengulangan data dalam interval tertentu. Kombinasi tersebut menjadikan SARIMA sebagai metode yang cukup kuat dalam memodelkan data yang bersifat fluktuatif namun tetap memiliki pola tertentu.

Menurut (Hyndman & Athanasopoulos, 2021), model SARIMA sangat efektif digunakan pada data yang memiliki pola musiman yang stabil serta struktur historis yang jelas. Model ini mampu menangkap hubungan historis antarperiode sehingga dapat menghasilkan prediksi yang lebih akurat pada data musiman. Selain itu, penelitian terbaru juga menunjukkan bahwa metode SARIMA masih menjadi salah satu pendekatan statistik yang relevan

dalam berbagai bidang, seperti ekonomi, kesehatan, cuaca, energi, hingga media digital karena memiliki kemampuan yang baik dalam membaca pola musiman dan tren data.

Dalam penelitian ini, metode SARIMA digunakan untuk menganalisis perubahan engagement YouTube RRI Pro 2 Malang berdasarkan variabel avg duration dan avg views pada setiap periode waktu. Penggunaan metode ini dinilai sesuai karena data engagement YouTube memiliki karakteristik yang berubah-ubah (fluktuatif) dan menunjukkan adanya pola musiman pada waktu tertentu. Dengan menggunakan SARIMA, pola historis jumlah penonton dapat dipelajari sehingga dapat digunakan untuk memprediksi jumlah views dan duration pada periode berikutnya secara lebih sistematis.

Selain mampu menangkap pola tren dan musiman, metode SARIMA juga memiliki keunggulan dalam mengolah data historis yang memiliki ketergantungan antarwaktu (time dependency). Hal tersebut sangat penting dalam penelitian ini karena perubahan jumlah views pada suatu periode sering kali dipengaruhi oleh performa konten pada periode sebelumnya. Dengan demikian, metode SARIMA tidak hanya membantu dalam proses prediksi, tetapi juga memberikan gambaran mengenai pola perilaku audiens terhadap konten yang dipublikasikan oleh RRI Pro 2 Malang.

Model SARIMA umumnya dituliskan dalam bentuk sebagai berikut:

$$SARIMA(p, d, q)(P, D, Q, s) \quad I$$

- p : orde *autoregressive* (AR)

- d: tingkat *differencing* non - musiman (I)
- q: orde *moving average* (MA) s
- P: orde *seasonal autoregressive*
- D: tingkat *differencing* musiman
- Q: Orde *seasonal moving average*
- s: panjang periode musiman

Secara sederhana, komponen dalam SARIMA dapat dijelaskan sebagai berikut :

1. *Autoregressive*(AR)

Komponen ini menggambarkan hubungan antara nilai saat ini dengan nilai sebelumnya. Dengan kata lain, data masa lalu digunakan untuk memprediksi data saat ini.

2. *Integrated*(I)

Merupakan sebuah proses *differencing* atau pembedaan data agar data menjadi lebih stabil (*stasioner*) dan mudah dianalisis.

3. *MovingAverage*(MA)

Komponen ini melihat hubungan antara nilai saat ini dengan kesalahan (*error*) pada periode sebelumnya.

4. *SeasonalComponent*

Komponen ini digunakan untuk menangkap pola berulang yang muncul pada periode tertentu, seperti pola bulanan atau tahunan.

Dalam penerapannya, metode SARIMA memiliki beberapa tahapan penting agar model yang dihasilkan dapat memberikan prediksi yang optimal, yaitu:

Tahapan Metode SARIMA

1. Identifikasi Model

Menentukan nilai parameter (p, d, q) dan (P, D, Q) dengan menggunakan ACF dan PACF.

2. Uji Stasioneritas

Memastikan data bersifat stabil *stasioner* melalui proses *differencing*.

3. Estimasi Parameter

Menghitung parameter terbaik yang paling sesuai dengan pola data.

4. Diagnostik Model

Menguji apakah model sudah sesuai dan residual acak.

5. Forecasting

Menghasilkan prediksi untuk periode mendatang berdasarkan pola historis data.

Beberapa penelitian terbaru juga menunjukkan bahwa metode SARIMA memiliki performa yang baik dalam berbagai bidang. Menurut penelitian (Kumari & Muthulakshmi, 2024) model SARIMA mampu menghasilkan tingkat akurasi yang tinggi dalam peramalan cuaca karena dapat membaca pola tren dan musiman secara bersamaan. Penelitian oleh (Ayiah-Mensah et al., 2025) juga menunjukkan bahwa model SARIMA mampu menghasilkan prediksi curah hujan yang akurat dengan nilai MAPE sebesar 5,97%, sehingga dinilai efektif untuk analisis data musiman. Sebelum tahap pemodelan dilakukan, data pada penelitian-penelitian tersebut umumnya turut

diuji stasioneritasnya menggunakan *Augmented Dickey-*

Fuller (ADF) Test dengan taraf signifikansi 0,05 sebagai konvensi umum dalam statistika inferensial.(Hyndman & Athanasopoulos, 2021).

Pada bidang media digital, penelitian dari (Nurmawati et al., 2024) menunjukkan bahwa pendekatan statistik berbasis ARIMA dan SARIMA dapat digunakan untuk menganalisis pola engagement media sosial dalam memprediksi perilaku wisatawan domestik. Selain itu, penelitian dari (Aishah et al., 2025) juga menjelaskan bahwa metode SARIMA masih menjadi model statistik yang kuat dalam memprediksi data musiman dibandingkan beberapa metode modern lainnya karena interpretasi modelnya lebih jelas dan stabil pada data historis.

Beberapa penelitian komparatif lain turut memperkuat posisi SARIMA sebagai metode yang unggul dalam berbagai konteks data musiman. Penelitian perbandingan pada data ekspor Sumatera Barat menemukan bahwa SARIMA menghasilkan MAPE sebesar 0,437%, jauh lebih rendah dibandingkan Holt-Winters yang menghasilkan MAPE 0,894%, sehingga SARIMA dinyatakan lebih unggul karena akurasinya yang lebih tinggi (Hasibuan et al., 2023). Hal serupa juga ditemukan pada penelitian milik (Mohd Lip et al., 2020) tentang peramalan kunjungan wisatawan internasional ke Malaysia, di mana SARIMA berhasil mencapai akurasi peramalan yang lebih unggul dengan nilai MAPE sebesar 5,31% dibandingkan model pembanding. Sementara itu, pada bidang keselamatan transportasi, penelitian yang dilakukan (Agyemang et al., 2023) menerapkan metode Box-Jenkins untuk mengidentifikasi model SARIMA

terbaik dalam meramalkan data kecelakaan lalu lintas bulanan, dengan mempertimbangkan nilai AIC dan BIC sebagai kriteria pemilihan model. Ketiga penelitian ini menunjukkan konsistensi keunggulan SARIMA pada data yang memiliki pola musiman yang jelas dan terstruktur, sekaligus mengonfirmasi relevansi penggunaan kriteria AIC seperti yang diterapkan dalam penelitian ini.

Dalam konteks penelitian ini, serta berbagai keunggulan tersebut. Metode SARIMA dipilih dalam penelitian ini karena dinilai mampu menangkap pola perubahan engagement YouTube yang bersifat dinamis, fluktuatif, dan musiman. Kemampuan model dalam memanfaatkan pola historis menjadikan SARIMA relevan untuk membantu proses analisis dan prediksi jumlah views pada kanal YouTube RRI Pro 2 Malang. Metode SARIMA digunakan untuk memodelkan data engagement audiens yang memiliki pola tren musiman, sehingga diharapkan mampu menghasilkan prediksi yang akurat berdasarkan pola historis yang telah terbentuk.

2.5 Metode *Triple Exponential Smoothing* (TES) (*Holt-Winters*)

Metode Triple Exponential Smoothing atau yang lebih dikenal sebagai metode Holt-Winters merupakan salah satu metode peramalan deret waktu (time series forecasting) yang digunakan untuk menganalisis data yang memiliki pola tren dan musiman secara bersamaan. Metode ini pertama kali diperkenalkan oleh Charles C. Holt pada tahun 1957, kemudian disempurnakan oleh Peter R. Winters pada tahun 1960 dengan menambahkan komponen musiman ke dalam model (Holt, 1957; Peter R. Winters, 1960). Berbeda dengan

metode pemulusan sederhana (single exponential smoothing) yang hanya cocok untuk data stabil tanpa pola musiman, metode Holt-Winters dirancang khusus untuk menangani data yang memiliki perubahan tren sekaligus pola musiman yang berulang dalam periode tertentu, seperti data bulanan, tahunan, maupun data digital yang bersifat dinamis. Kemampuan ini menjadikan metode Holt-Winters relevan digunakan pada data historis yang kompleks, karena pola dasar deret waktunya dapat teridentifikasi secara lebih presisi.

Dalam penelitian ini, metode Holt-Winters digunakan untuk menganalisis perubahan engagement YouTube RRI Pro 2 Malang berdasarkan variabel avg duration dan avg views" pada setiap periode waktu. Penggunaan metode ini dinilai relevan karena data engagement YouTube memiliki pola yang fluktuatif sekaligus menunjukkan pola musiman pada periode tertentu. Karakteristik data semacam ini sejalan dengan tujuan awal pengembangan metode Holt-Winters, yang dirancang khusus untuk menghasilkan peramalan secara rutin dan responsif terhadap perubahan kondisi data dari waktu ke waktu. Sesuai dengan yang pertama kali dikemukakan oleh (Winters, 1960) sebagai perluasan dari metode Holt untuk data yang memiliki kondisi berubah..

Sebagai contoh, peningkatan jumlah penonton sering terjadi pada momentum tertentu, seperti bulan Ramadan, hari libur nasional, maupun peristiwa besar yang tengah menjadi perhatian publik. Pola tersebut menunjukkan bahwa data views tidak bergerak secara acak, melainkan memiliki pola historis yang dapat dipelajari dan diprediksi menggunakan metode Holt-Winters.

Fenomena peningkatan aktivitas audiens pada momentum atau periode tertentu ini juga banyak ditemukan dalam penelitian-penelitian sejenis, misalnya pada peramalan dari (Mohd Lip et al., 2020) tentang kunjungan wisatawan yang menunjukkan pola musiman terkait hari libur dan musim tertentu, sehingga metode peramalan musiman seperti Holt-Winters dinilai tepat digunakan untuk menangkap pola semacam ini.

Keunggulan utama metode Holt-Winters terletak pada kemampuannya dalam memberikan bobot lebih besar pada data terbaru dibandingkan data lama, karena bobot pada data historis menurun secara eksponensial seiring bertambahnya usia data (Hyndman & Athanasopoulos, 2021). Dengan kata lain, model akan lebih responsif terhadap perubahan perilaku audiens terkini. Hal ini sangat penting dalam analisis media digital karena tren konten dan perilaku pengguna internet dapat berubah dengan cepat mengikuti perkembangan informasi dan preferensi audiens.

Metode Holt-Winters memiliki dua pendekatan utama (Hyndman & Athanasopoulos, 2021), yaitu :

1. Model Aditif (*Additive*)

Digunakan apabila pola musiman memiliki rentang fluktuasi yang relatif stabil dari waktu ke waktu.

2. Model Multiplikatif (*Multiplicative*)

Digunakan saat pola musiman mengalami peningkatan atau penurunan mengikuti perubahan tren data.

Dalam proses peramalan, metode Holt-Winters terdiri dari tiga

komponen utama, yaitu level, tren, dan musiman (Hyndman & Athanasopoulos, 2021). Ketiga komponen tersebut saling terhubung untuk menghasilkan prediksi yang optimal, yakni:

1. Pemulusan Level / rata - rata (Parameter α / *Alpha*)

Komponen ini digunakan untuk memperkirakan nilai dasar (*baseline*) data setelah pengaruh tren dan musiman dihilangkan.

$$L_t = \alpha S_t - s Y_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad 2$$

Keterangan :

- L_t = level data pada periode ke- t
- Y_t = data aktual
- S_{t-s} = indeks musiman
- α = parameter level
- T_{t-1} = tren sebelumnya

Semakin besar nilai α , maka model akan semakin cepat menyesuaikan diri terhadap perubahan data terbaru.

2. Pemulusan Tren (Parameter β / *Beta*)

Komponen ini digunakan untuk memperkirakan nilai dasar (*baseline*) data setelah pengaruh tren dan musiman dihilangkan.

$$T_t = \beta (L_t - L_{t-1}) + (1 - \beta) T_{t-1} \quad 3$$

Keterangan :

- T_t = nilai tren
- β = parameter tren
- $L_t - L_{t-1}$ = perubahan level data

Komponen ini membantu model memahami apakah data sedang mengalami kenaikan atau penurunan.

1. **Pemulusan Musiman (Parameter γ / *Gamma*)**

Komponen ini digunakan untuk memperbarui pola musiman yang muncul secara berulang.

$$S_t = \gamma L_t Y_t + (1 - \gamma) S_{t-s} \quad 4$$

Keterangan :

- S_t = indeks musiman
- Y = parameter musiman
- S = panjang periode musiman

Tanpa komponen ini, model tidak dapat mengenali pola kenaikan penonton pada bulan-bulan tertentu.

Dalam penerapannya, metode Holt-Winters memiliki beberapa tahapan penting, yaitu:

1. Identifikasi pola tren dan musiman.
2. Menentukan parameter α , β , dan γ .
3. Melakukan proses pemulusan level, tren, dan musiman.
4. Mengevaluasi tingkat kesalahan model menggunakan MAPE atau RMSE.
5. Menghasilkan prediksi untuk periode mendatang.

Berbagai penelitian terbaru menunjukkan bahwa metode Holt-Winters masih memiliki performa yang sangat baik dalam memprediksi data musiman dan fluktuatif. Penelitian oleh (Kumar et al., 2024) menunjukkan bahwa

metode Holt-Winters mampu menghasilkan prediksi yang stabil pada data deret waktu musiman dibandingkan beberapa metode statistik lainnya.

Penelitian oleh (Asafo et al., 2024) juga menjelaskan bahwa model Holt-Winters Additive mampu digunakan secara efektif dalam proses prediksi data energi jangka panjang karena dapat menangkap pola tren dan musiman secara bersamaan.

Selain itu, penelitian oleh (Ensafi et al., 2022) menjelaskan bahwa metode Triple Exponential Smoothing memiliki kemampuan membaca pola tren dan musiman dengan memberikan bobot lebih besar pada data terbaru, sehingga model lebih adaptif terhadap perubahan data. Selanjutnya, penelitian oleh (Rumbe et al., 2024) menunjukkan bahwa metode Holt-Winters tetap relevan digunakan pada data bisnis dan digital karena mampu menghasilkan prediksi yang stabil pada data yang mengalami perubahan musiman.

Di sisi lain, sejumlah penelitian juga menunjukkan bahwa Holt-Winters dapat mengungguli SARIMA pada karakteristik data tertentu, khususnya data yang menunjukkan perubahan pola secara cepat. Penelitian perbandingan pada data kunjungan wisata (Evania & Siregar, 2024) menemukan bahwa Holt-Winters menghasilkan MAPE sebesar 5,2631%, lebih rendah dibandingkan SARIMA yang menghasilkan MAPE 5,8920%, sehingga Holt-Winters direkomendasikan sebagai model yang lebih sesuai untuk kasus tersebut.

Demikian pula, pada penelitian dari (Mohd Lip et al., 2020) tentang peramalan kedatangan wisatawan ke Malaysia, Holt-Winters ditemukan lebih tepat digunakan khusus untuk memprediksi kedatangan wisatawan dari Inggris

dan Korea, meskipun secara umum SARIMA unggul pada kelompok data lainnya. Pada bidang asuransi, (Apaka & Rotich, 2025) penelitian klaim asuransi kendaraan di Kenya turut mengonfirmasi relevansi Holt-Winters sebagai model musiman, dengan pola musiman yang teridentifikasi pada data klaim menjadi dasar pemilihan model Holt-Winters multiplikatif sebagai salah satu model optimal, berdampingan dengan SARIMA. Penelitian-penelitian ini memperkuat argumen bahwa performa kedua metode bersifat sangat bergantung pada karakteristik data yang dianalisis, sehingga relevan untuk diuji secara langsung pada kasus data engagement YouTube RRI Pro 2 Malang.

Berdasarkan berbagai penelitian tersebut, metode Holt-Winters dipilih dalam penelitian ini karena dinilai mampu menangkap pola perubahan engagement YouTube yang bersifat dinamis, fluktuatif, dan musiman. Kemampuan metode ini dalam memanfaatkan pola historis serta menyesuaikan diri terhadap perubahan data terbaru menjadikan Holt-Winters relevan untuk membantu proses analisis dan prediksi jumlah views pada kanal YouTube RRI Pro 2 Malang.

2.6 Skala akurasi peramalan

Skala akurasi peramalan merupakan salah satu bagian penting dalam penelitian prediksi deret waktu (time series forecasting) karena digunakan untuk mengetahui seberapa dekat hasil prediksi dengan data sebenarnya. Dalam penelitian ini, skala akurasi digunakan sebagai alat pembanding untuk mengevaluasi performa metode SARIMA dan Holt-Winters dalam memprediksi perubahan engagement YouTube RRI Pro 2 Malang. Semakin

kecil nilai kesalahan (error) yang dihasilkan oleh suatu metode, maka semakin baik tingkat akurasi model tersebut dalam melakukan prediksi.

Secara sederhana, akurasi peramalan dapat dipahami sebagai ukuran keberhasilan model dalam menebak kondisi yang akan terjadi di masa mendatang berdasarkan data historis sebelumnya. Apabila hasil prediksi mendekati data aktual, maka model dianggap memiliki performa yang baik. Sebaliknya, jika selisih antara hasil prediksi dan data aktual terlalu besar, maka model dianggap kurang akurat.

Menurut (Hyndman & Koehler, 2006) dalam penelitian *Another Look at Measures of Forecast Accuracy*, akurasi peramalan merupakan ukuran untuk mengetahui tingkat kedekatan hasil prediksi terhadap data sebenarnya. Penelitian tersebut menjelaskan bahwa evaluasi akurasi sangat penting karena model prediksi yang baik harus memiliki tingkat kesalahan yang sekecil mungkin. Teori ini menjadi dasar dalam penelitian untuk membandingkan metode SARIMA dan Holt-Winters pada data engagement YouTube RRI Pro 2 Malang.

Salah satu ukuran akurasi yang paling banyak digunakan dalam penelitian deret waktu adalah Mean Absolute Percentage Error (MAPE). MAPE digunakan karena mampu menunjukkan besar kesalahan prediksi dalam bentuk persentase, sehingga lebih mudah dipahami dan diinterpretasikan oleh peneliti maupun pembaca umum ((Hyndman & Koehler, 2006). Nilai MAPE yang semakin kecil menunjukkan bahwa hasil prediksi semakin mendekati data aktual.

Rumus MAPE dapat dituliskan sebagai berikut :

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad 5.$$

Keterangan :

- A_t = Nilai Aktual pada periode ke- t
- F_t = Nilai hasil prediksi pada periode ke- t
- N = jumlah data
- $A_t - F_t$ = nilai absolut error

Secara sederhana, rumus tersebut digunakan untuk menghitung rata-rata persentase kesalahan antara data aktual dengan data hasil prediksi. Sebagai contoh, jika nilai MAPE sebesar 5%, maka dapat diartikan bahwa rata-rata kesalahan prediksi hanya sebesar 5% dari data sebenarnya. Oleh karena itu, semakin kecil nilai MAPE, maka model dianggap semakin baik dalam melakukan prediksi.

Selain MAPE, penelitian ini juga menggunakan ukuran akurasi lain seperti Root Mean Squared Error (RMSE). Kedua metrik ini digunakan untuk mengetahui besar kesalahan prediksi berdasarkan kuadrat error, sehingga model dengan kesalahan besar akan lebih terlihat pengaruhnya (Hyndman & Koehler, 2006).

Rumus RMSE :

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2} \quad 6.$$

- RMSE merupakan akar dari nilai MSE
- Sering digunakan untuk mengetahui besar error dalam satuan yang sama dengan data aslinya.
- Nilai RMSE yang kecil menunjukkan bahwa hasil dari prediksi mendekati data aktual.

Untuk menginterpretasikan seberapa baik nilai MAPE yang dihasilkan oleh suatu model peramalan, penelitian ini mengacu pada skala interpretasi MAPE yang dikemukakan oleh (C. D. Lewis, 1982), sebagaimana disajikan pada Tabel 2.2 berikut.

Tabel 2. 1 Skala Interpretasi MAPE
Sumber : (C.D Lewis, 1982)

NILAI MAPE	INTERPRESTASI
<10%	Sangat Akurat
10% - 20%	Baik
20% - 50%	Cukup atau Wajar
>50%	Tidak Akurat

Berdasarkan skala tersebut, semakin kecil nilai MAPE yang dihasilkan suatu model, semakin baik pula tingkat akurasi model tersebut dalam melakukan prediksi. Skala ini digunakan sebagai acuan dalam penelitian ini untuk menilai kelayakan hasil peramalan, baik pada model SARIMA maupun TES (Holt-Winters), pada masing-masing variabel penelitian.

Dalam penelitian ini, penggunaan MAPE menjadi sangat penting

karena data engagement YouTube berupa jumlah views lebih mudah dianalisis dalam bentuk persentase kesalahan. Dengan demikian, hasil evaluasi model dapat memberikan gambaran yang lebih jelas mengenai tingkat keakuratan prediksi jumlah penonton pada kanal YouTube RRI Pro 2 Malang.

Dari berbagai penelitian terbaru juga menunjukkan bahwa pengukuran akurasi menggunakan MAPE, RMSE masih menjadi pendekatan utama dalam evaluasi model peramalan. Penelitian oleh (Khan & Osínska, 2023) menjelaskan bahwa MAPE dan RMSE merupakan indikator yang efektif dalam membandingkan performa model deret waktu karena mampu menunjukkan tingkat kesalahan prediksi secara jelas dan mudah dipahami..

Penelitian oleh (Cerasa & Zani, 2025) juga menunjukkan bahwa peningkatan akurasi peramalan dapat diketahui melalui penurunan nilai forecasting error. Penelitian tersebut menegaskan bahwa evaluasi akurasi sangat penting dalam menentukan model terbaik pada data yang bersifat fluktuatif. Penelitian lainnya oleh (Akinrogunde et al., 2025) juga menjelaskan bahwa ukuran akurasi seperti MAPE, RMSE, masih menjadi indikator utama dalam evaluasi model forecasting modern karena mudah dipahami dan mampu memberikan interpretasi performa model secara kuantitatif.

Dari berbagai penelitian tersebut, skala akurasi peramalan menjadi bagian yang sangat penting dalam penelitian ini karena digunakan untuk menentukan metode terbaik antara SARIMA dan Holt-Winters. Model dengan nilai error terkecil akan dianggap lebih mampu memprediksi pola perubahan engagement YouTube RRI Pro 2 Malang secara akurat dan stabil. Dengan

demikian, hasil evaluasi akurasi tidak hanya menunjukkan performa model, tetapi juga membantu menentukan metode yang paling efektif dalam mendukung analisis perkembangan audiens digital pada kanal YouTube RRI Pro 2 Malang.