

Evaluasi Model Prediktif untuk Peramalan Pencairan Kredit Menggunakan Time Series

Fadhli Jahfal Aufa Maulana¹, Rizwar Syaefulloh², Najlia Intani³,

Nadine Valia Azzahra⁴, Adri Arisena⁵

Universitas Koperasi Indonesia^{1,2,3,4,5}

adri@ikopin.ac.id⁵

ABSTRAK

Pencairan kredit merupakan indikator penting dalam sektor keuangan yang memengaruhi stabilitas ekonomi. Penelitian ini bertujuan untuk mengevaluasi performa tiga model prediktif berbasis deret waktu, yaitu ARIMA, ETS, dan Prophet, dalam meramalkan pencairan kredit bulanan. Data yang digunakan mencakup periode Februari 2022 hingga 2031 dan menunjukkan karakteristik volatil dengan adanya outlier signifikan. Metode penelitian meliputi uji stasioneritas (ADF, ACF, PACF), pembersihan data melalui imputasi outlier menggunakan moving average, serta pembangunan dan evaluasi model. Hasil analisis menunjukkan bahwa data bersifat stasioner, tetapi model ARIMA(0,0,0) dan ETS(M,N,M) pada data mentah menghasilkan akurasi rendah (MAPE > 178%). Setelah imputasi outlier, terjadi peningkatan signifikan pada kinerja model. Model Prophet mencatat performa terbaik dengan nilai RMSE (4.483.520), MAE (3.274.253), dan MAPE (85,11%), mampu menangkap tren non-linear dan pola musiman secara lebih efektif dibandingkan ARIMA dan ETS. Kesimpulan penelitian ini merekomendasikan penggunaan Model Prophet untuk peramalan pencairan kredit, dengan catatan pentingnya preprocessing data dan evaluasi berkala untuk menjaga akurasi prediksi.

Kata Kunci: pencairan kredit, deret waktu, ARIMA, ETS, prophet, peramalan

I. PENDAHULUAN

Pencairan kredit merupakan indikator vital dalam stabilitas dan pertumbuhan ekonomi, karena mencerminkan seberapa besar aktivitas pembiayaan yang dilakukan oleh lembaga keuangan kepada masyarakat atau pelaku usaha (Bank Indonesia, 2022). Informasi tentang tren pencairan kredit sangat diperlukan untuk memprediksi kebutuhan likuiditas, mengelola risiko kredit, dan menyusun strategi keuangan jangka panjang. Fluktuasi pencairan kredit yang signifikan menunjukkan adanya kompleksitas pola dalam data, yang tidak selalu bersifat linier maupun musiman. Oleh karena itu, analisis deret waktu (*time series analysis*) menjadi pendekatan penting untuk memahami dinamika ini dan melakukan peramalan jangka pendek maupun jangka panjang (Hyndman & Athanasopoulos, 2018).

Metode peramalan seperti ARIMA (*AutoRegressive Integrated Moving Average*) banyak digunakan karena mampu menangani komponen autokorelasi serta tren dalam data stasioner (Box et al., 2015). Namun, model ini terbatas ketika menghadapi data dengan *outlier* atau non-linearitas musiman. Oleh karena itu, pendekatan lain seperti ETS (*Exponential Smoothing State Space Model*) dan *Prophet* dikembangkan untuk menangani data non-stasioner dan kompleksitas musiman yang tidak dapat dijelaskan oleh model klasik (Taylor & Letham, 2018; Hyndman et al., 2002). Dalam penelitian ini, dilakukan evaluasi dan perbandingan performa tiga model prediktif ARIMA, ETS, dan Prophet pada data bulanan pencairan kredit. Pendekatan ini mencakup tahap imputasi data untuk menangani outlier yang signifikan, serta analisis akurasi peramalan. Hasil dari analisis ini diharapkan dapat memberikan wawasan bagi lembaga keuangan dalam memilih model terbaik untuk forecasting pencairan kredit.

II. TINJAUAN PUSTAKA

Deret Waktu (*Time Series*)

Deret waktu adalah urutan data yang dikumpulkan secara berkala berdasarkan waktu. Tujuan utama analisis deret waktu adalah untuk memahami struktur data masa lalu dan memprediksi nilai masa depan (Chatfield, 2003). Data time series umumnya terdiri atas komponen tren, musiman, siklus, dan *noise* (Makridakis et al., 1998). Sebuah model peramalan yang efektif harus mampu menangani komponen-komponen tersebut secara akurat.

ARIMA (*AutoRegressive Integrated Moving Average*)

Model ARIMA diperkenalkan oleh Box dan Jenkins (1976) dan banyak digunakan dalam peramalan keuangan karena kemampuannya dalam menangani data stasioner melalui proses differencing. Model ini sangat bergantung pada identifikasi nilai optimal dari parameter (p , d , q), serta pengujian stasioneritas menggunakan ADF (*Augmented DickeyFuller*) atau KPSS (Kwiatkowski–Phillips–Schmidt–Shin) test (Hyndman & Athanasopoulos, 2018).

ETS (*Exponential Smoothing State Space Model*)

ETS merupakan metode pemulusan yang menggabungkan komponen *error*, *trend*, dan *seasonality* dalam model *state-space*. ETS dikenal lebih fleksibel untuk data dengan karakteristik tren dan musiman eksplisit, terutama dalam kondisi data dengan *noise* tinggi (Hyndman et al., 2002). Model ETS cocok untuk kasus di mana ARIMA tidak dapat menangkap pola musiman yang tidak eksplisit.

Prophet

Prophet adalah model peramalan aditif berbasis *decomposable time series* yang dikembangkan oleh Facebook (Taylor & Letham, 2018). *Prophet* dirancang untuk bekerja secara baik pada data bisnis dan keuangan dengan tren non-linear dan *outlier* signifikan. *Prophet* membagi data menjadi tiga komponen utama: *trend*, *seasonality*, dan *holiday effects*, serta memungkinkan fleksibilitas tinggi dalam menangani *missing value* dan *outlier*.

Evaluasi Performa Model

Akurasi model peramalan biasanya diukur dengan menggunakan indikator seperti *Mean Absolute Percentage Error* (MAPE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE). Nilai MAPE yang tinggi menunjukkan bahwa model memiliki error prediksi yang signifikan terhadap nilai aktual (Makridakis et al., 1998; Hyndman & Koehler, 2006). Oleh karena itu, dalam studi ini, seluruh model dievaluasi dengan pendekatan kuantitatif berdasarkan indikator tersebut.

III. METODE PENELITIAN

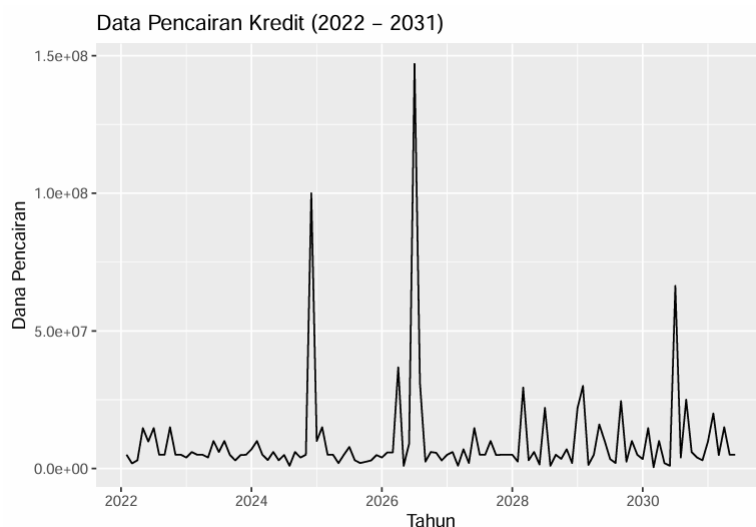
Penelitian ini menggunakan pendekatan kuantitatif dengan analisis deret waktu untuk mengevaluasi dan membandingkan model ARIMA, ETS, dan *Prophet* dalam peramalan pencairan kredit bulanan periode 2022–2031. Tahapan serta detail metode adalah sebagai berikut:

Penelitian dilakukan melalui tahap-tahap berikut:

1. **Pengumpulan data:** data yang digunakan merupakan data bulanan pencairan kredit, diperoleh dari lembaga keuangan terkait. Data dikumpulkan secara runtut waktu untuk memastikan kelengkapan dan keakuratan observasi.
2. **Pra-pemrosesan Data**
 - a. Pemeriksaan dan Penanganan Outlier: data diperiksa untuk mendeteksi adanya outlier dan fluktuasi ekstrim menggunakan visualisasi time series dan metode statistik. Outlier yang teridentifikasi ditangani melalui teknik imputasi data untuk meningkatkan kualitas dan kestabilan data sebelum pemodelan;
 - b. Pengujian Stasioneritas: stasioneritas data diuji menggunakan Augmented Dickey-Fuller (ADF) test, plot ACF, dan PACF untuk memastikan data memenuhi asumsi deret waktu yang diperlukan;
 - c. Transformasi Data: Jika diperlukan, transformasi tambahan dilakukan guna menyesuaikan data dengan karakteristik model yang akan digunakan.
3. Pemodelan
 - a. Penerapan Model ARIMA: Model ARIMA (*AutoRegressive Integrated Moving Average*) diaplikasikan dengan penentuan parameter berdasarkan hasil pengujian ACF, PACF, dan uji stasioneritas;
 - b. Penerapan Model ETS: Model ETS (*Exponential Smoothing State Space Model*) diterapkan guna menangkap pola tren dan musiman eksplisit, khususnya pada kondisi data bersifat non-stasioner dan volatil.
 - c. Penerapan *Model Prophet*: *Model Prophet* yang berbasis *decomposable time series* diterapkan untuk mengakomodasi tren non-linear, musiman tahunan, dan efek *outlier* secara fleksibel.
4. Evaluasi Model
 - a. Indikator Evaluasi: akurasi model dievaluasi menggunakan tiga indikator utama, yaitu (1) *mean absolute percentage error (MAPE)*, *root mean squared error (RMSE)*, dan *mean absolute error (MAE)*;
 - b. Perbandingan performa: ketiga model dibandingkan berdasarkan skor evaluasi dan kemampuan dalam menangkap pola tren dan musiman pada data setelah dilakukan imputasi outlier.
5. Validasi Hasil
 - a. Visualisasi Hasil Peramalan: Hasil peramalan dari masing-masing model divisualisasikan dan dibandingkan terhadap data aktual untuk menilai keakuratan, stabilitas, dan konsistensi model;
 - b. Analisis Kualitatif: Selain evaluasi kuantitatif, analisis kualitatif dilakukan untuk mengidentifikasi kelebihan dan kekurangan masing-masing model pada karakteristik data pencairan kredit.
6. Penarikan Simpulan: Berdasarkan hasil evaluasi kuantitatif dan kualitatif, dipilih model prediktif paling optimal untuk peramalan pencairan kredit di masa mendatang, dengan memberikan rekomendasi penerapan di lingkungan lembaga keuangan terkait.

IV. HASIL PENELITIAN DAN PEMBAHASAN

A. Plot Data *Time Series* Awal



Gambar 1. Plot Time Series Data Pencairan Kredit (2022-2031)

Plot deret waktu menampilkan data pencairan kredit bulanan dari Februari 2022 hingga akhir 2031, yang secara visual menyoroti karakteristik penting data. Terlihat jelas adanya fluktuasi nilai yang sangat tinggi sepanjang periode observasi, disertai dengan lonjakan ekstrem atau *outlier* yang signifikan pada beberapa titik waktu, yang mengindikasikan tingginya volatilitas data. Meskipun tidak ada tren linier jangka panjang yang jelas secara visual, pola pergerakan data didominasi oleh variabilitas yang substansial, menunjukkan bahwa data ini merupakan deret waktu yang kompleks dan memerlukan penanganan khusus, seperti identifikasi dan mitigasi outlier, sebelum dapat dimodelkan secara efektif untuk tujuan peramalan.

B. Uji Stasioneritas Data

Sebelum melakukan pemodelan deret waktu, penting untuk menguji dan memastikan stasioneritas data. Stasioneritas merupakan prasyarat utama dalam banyak metode peramalan deret waktu yang mengandalkan kestabilan rata-rata, varians, serta pola autokorelasi sepanjang periode observasi. Data yang tidak stasioner dapat menghasilkan estimasi parameter model yang bias dan peramalan yang tidak akurat. Untuk menguji stasioneritas data pencairan kredit ini, dilakukan uji ADF, ACF Test, dan PACF Test.

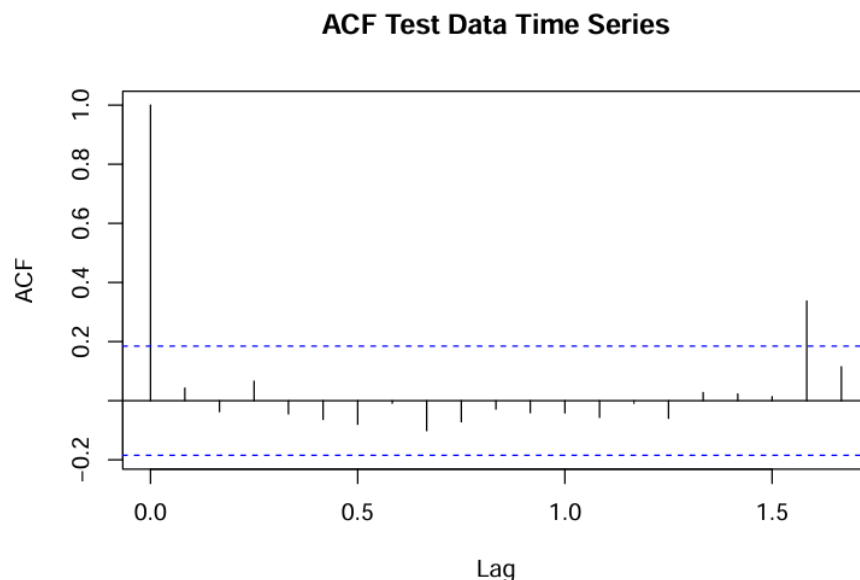
1. Uji Augmented Dickey-Fuller (ADF)

Uji Augmented Dickey-Fuller (ADF) dilakukan pada data pencairan kredit asli untuk menilai stasioneritasnya. Dengan hipotesis nol bahwa data tidak stasioner dan hipotesis alternatif bahwa data stasioner, hasil uji menunjukkan nilai *p-value* sebesar 0.01, nilai *p-value* yang sangat rendah ini memungkinkan kita untuk menolak hipotesis nol. Sehingga dapat disimpulkan bahwa data pencairan kredit asli telah bersifat stasioner sebelum dilakukan proses penanganan outlier sekalipun. Hasil ini mengindikasikan bahwa rata-rata, varians, dan struktur

autokorelasi data cenderung konstan seiring waktu, meskipun data tersebut masih mengandung fluktuasi ekstrem dan outlier yang dapat memengaruhi kinerja model.

2. ACF Test


Plot Fungsi Autokorelasi (ACF) menyajikan koefisien korelasi antara observasi deret waktu pada periode sekarang dengan nilai-nilai pada periode sebelumnya (*lag*). Pada plot ini, terlihat bahwa batang autokorelasi menurun secara cepat dan signifikan menuju nol setelah lag pertama. Sebagian besar batang korelasi berada dalam area bayangan biru, yang merepresentasikan batas kepercayaan 95%. Pola penurunan autokorelasi yang cepat ini merupakan indikator kuat bahwa data deret waktu pencairan kredit adalah stasioner. yang merupakan salah satu indikator bahwa data deret waktu bersifat stasioner. Artinya, rata-rata, variansi, dan struktur kovarians (termasuk autokorelasi) cenderung konstan dari waktu ke waktu. Oleh karena itu, differencing tambahan tidak diperlukan, dan model dapat dibangun langsung pada data asli.



Gambar 2. Plot ACF Test

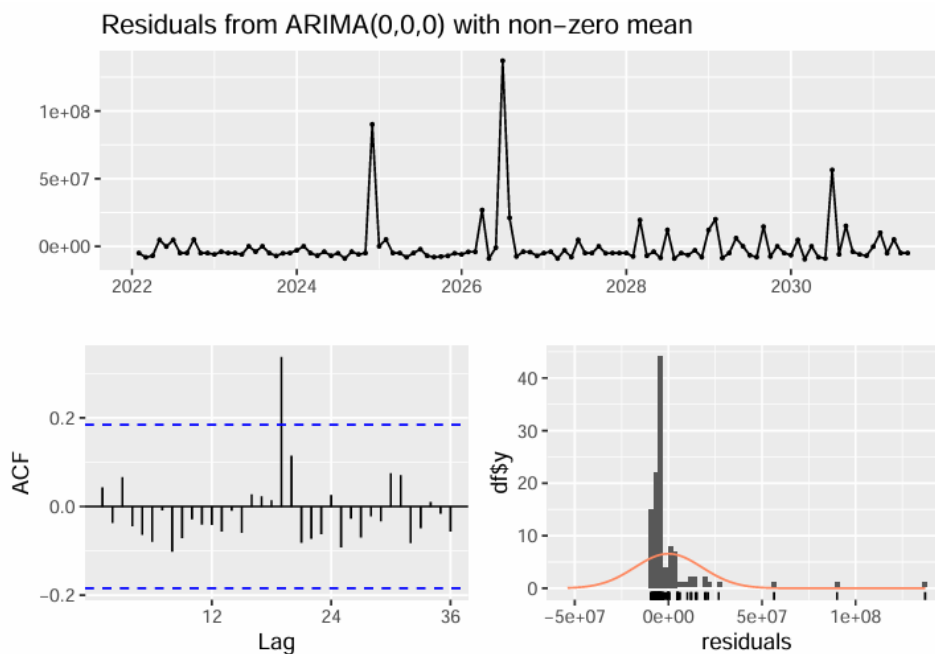
3. PACF Test

Plot Fungsi Autokorelasi Parsial (PACF) pada Gambar 3 menggambarkan korelasi langsung antara observasi deret waktu saat ini dengan observasi pada *lag* sebelumnya, setelah menghilangkan pengaruh dari *lag* di antaranya. Pada plot ini, terlihat adanya batang korelasi yang signifikan pada *lag* 0 dan *lag* 1, mengindikasikan adanya korelasi langsung yang kuat antara observasi saat ini dengan dirinya sendiri serta dengan observasi satu periode sebelumnya. Namun, setelah *lag* 1, koefisien korelasi parsial menurun drastis dan secara cepat berada di dalam batas kepercayaan (area bayangan biru), menunjukkan bahwa korelasi menjadi tidak signifikan pada *lag* berikutnya. Pola PACF dengan satu *spike* signifikan yang diikuti penurunan cepat seperti ini sering menjadi indikasi bagi penentuan orde AR dalam model ARIMA. Keseluruhan pola ini juga konsisten dengan temuan sebelumnya yang menyatakan bahwa data deret waktu sudah stasioner.



Gambar 3. Plot PACF Test


C. Analisis & Hasil Prediksi Model ARIMA 12 Bulan ke Depan (Sebelum Imputasi *Outlier*)



Gambar 4. Plot Model ARIMA(0,0,0)

Berdasarkan Plot yang ditampilkan, secara keseluruhan menjelaskan bahwa meskipun analisis ACF1 menunjukkan residual yang baik, nilai σ^2 yang sangat besar dan terutama nilai MAPE yang ekstrem (178.9871%) secara jelas mengindikasikan bahwa model ARIMA(0,0,0) ini sama sekali tidak cocok untuk memprediksi data pencairan kredit dalam kondisi aslinya. Model ini hanya mampu memprediksi nilai rata-rata, yang tidak merepresentasikan pola data yang sebenarnya karena adanya outlier dan volatilitas ekstrem.

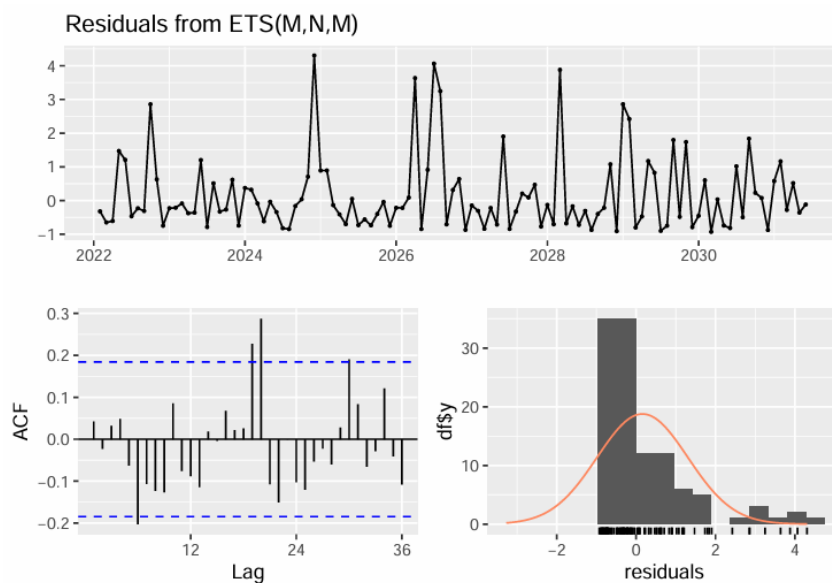
Hal ini menegaskan bahwa data mentah sangat *noisy* dan memerlukan *preprocessing*, khususnya penanganan *outlier*, sebelum dapat dimodelkan secara efektif.



Gambar 5. Plot Model ARIMA Prediksi 12 Bulan ke Depan

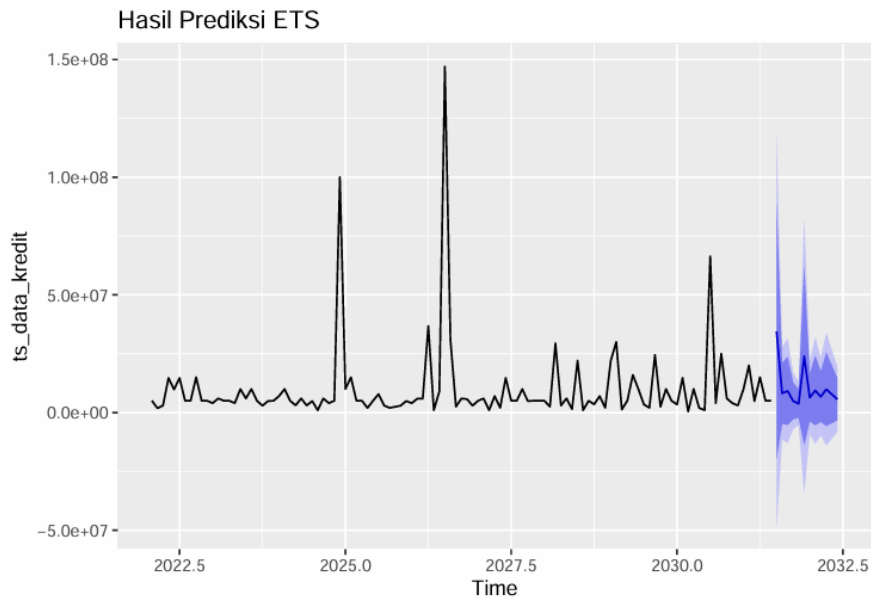
Plot menyajikan prediksi dari model ARIMA(0,0,0) pada data pencairan kredit asli, dengan jelas menegaskan bahwa data deret waktu pencairan kredit dalam kondisi aslinya, yang dicirikan oleh adanya outlier dan variabilitas tinggi, sangat sulit untuk diprediksi secara akurat menggunakan model ARIMA(0,0,0). Hal ini ditunjukkan oleh prediksi yang cenderung konstan pada rata-rata dan interval kepercayaan yang sangat lebar, mencerminkan ketidakmampuan model untuk menangkap pola dinamis data dan menghasilkan peramalan yang andal.

D. Analisis & Hasil Prediksi Model *Exponential Smoothing* (ETS) (Sebelum Imputasi *Outlier*)



Gambar 6. Plot Model ETS(M,N,M)

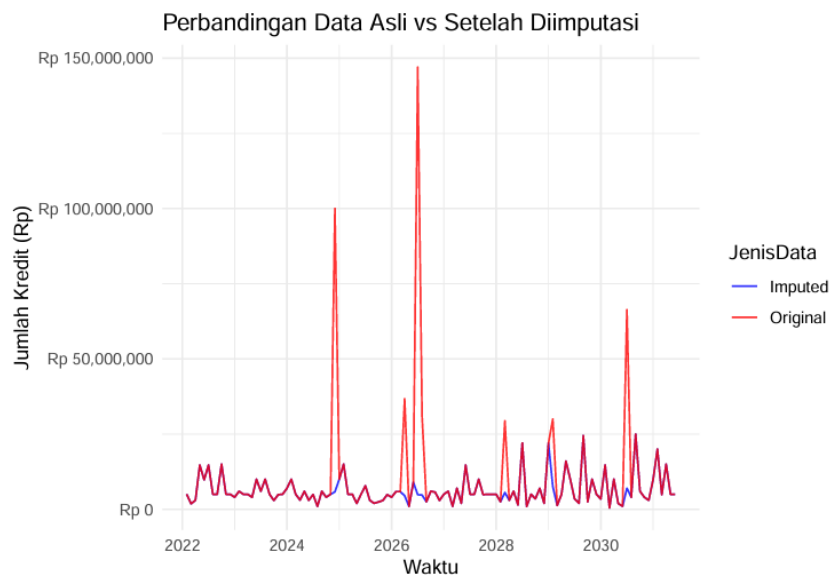
Plot menampilkan peramalan dari model ETS(M,N,M) pada data pencairan kredit asli, menunjukkan bahwa meskipun model ini memiliki kemampuan untuk mengenali dan mencoba mereplikasi pola musiman dalam data historis, namun peramalan secara keseluruhan masih sangat terbatas. Kehadiran *spikes* atau *outlier* yang tinggi dalam data asli menyebabkan model kesulitan untuk menghasilkan prediksi yang akurat dan stabil, terlihat dari fluktuasi besar dalam garis prediksi dan rentang kepercayaan yang mungkin masih lebar. Hal ini menegaskan bahwa, serupa dengan model ARIMA sebelumnya, karakteristik data yang *noisy* dan adanya outlier signifikan menjadikan model ETS kurang efektif dalam memprediksi data pencairan kredit tanpa adanya tahap preprocessing data yang lebih lanjut.



Gambar 7. Plot Model ETS Prediksi 12 Bulan ke Depan

Plot hasil prediksi yang dihasilkan oleh model ETS(M,N,M) pada data pencairan kredit asli, secara jelas menunjukkan keterbatasan model ini dalam menghasilkan peramalan yang akurat. Ketidakmampuan model untuk memberikan prediksi yang stabil dengan interval kepercayaan yang sempit secara kuat mengindikasikan bahwa keberadaan *outlier* dan tingkat volatilitas ekstrem pada data mentah membuat model ETS menjadi kurang efektif. Hasil yang serupa dengan model ARIMA sebelumnya, yang juga kesulitan pada data mentah, menekankan pentingnya tahap *preprocessing* data yang komprehensif, khususnya melalui imputasi outlier, sebelum pemodelan deret waktu dapat menghasilkan peramalan yang lebih informatif.

E. Perbaikan Data: Imputasi *Outlier*




Gambar 8. Plot Perbandingan Data Asli dengan Hasil Setelah Imputasi

Plot secara jelas menyajikan perbandingan visual antara data pencairan kredit asli (ditampilkan dalam garis berwarna merah) dan data yang telah melalui proses penanganan outlier dan imputasi (ditampilkan dalam garis berwarna biru), di mana lonjakan nilai ekstrem pada data asli telah berhasil dihaluskan menjadi pola yang lebih stabil dan konsisten. Transformasi ini sangat penting karena menghasilkan data yang lebih bersih dan mengurangi volatilitas, sehingga data pencairan kredit kini lebih sesuai untuk diterapkan pada model deret waktu guna menghasilkan peramalan yang lebih akurat dan andal.

F. Peramalan dengan Model ARIMA & ETS Setelah Imputasi *Outlier*

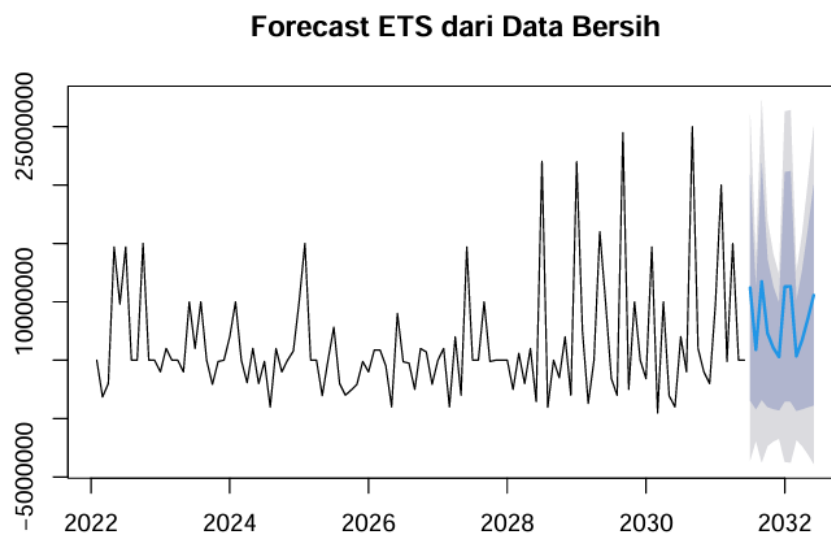
Forecast ARIMA Data Bersih



Gambar 9. Plot Hasil Prediksi Model ARIMA setelah Imputasi *Outlier*

Plot menampilkan peramalan yang dihasilkan oleh model ARIMA pada data pencairan kredit setelah proses penanganan dan imputasi *outlier*. Dibandingkan dengan hasil peramalan pada data asli sebelumnya, plot ini menunjukkan peningkatan signifikan dalam kualitas dan


keandalan prediksi. Garis prediksi kini tampak lebih stabil dan mampu menangkap pola yang lebih konsisten dalam data. Ini secara jelas mengindikasikan bahwa preprocessing data melalui imputasi outlier telah berhasil mengurangi ketidakpastian secara drastis, memungkinkan model ARIMA untuk menghasilkan peramalan yang lebih presisi, sehingga menunjukkan efektivitas penanganan outlier dalam meningkatkan kinerja model.



Gambar 10. Plot Hasil Prediksi Model ETS setelah Imputasi *Outlier*


Plot menampilkan peramalan yang dihasilkan oleh model ETS pada data pencairan kredit setelah proses penanganan dan imputasi outlier. Perbandingan dengan peramalan ETS pada data asli menunjukkan peningkatan yang nyata dalam akurasi dan stabilitas prediksi. Garis peramalan terlihat lebih konsisten dan mulus, berhasil menangkap pola yang ada. Hal ini menunjukkan bahwa preprocessing data melalui imputasi outlier telah berhasil mengurangi ketidakpastian peramalan secara drastis, sehingga memungkinkan model ETS untuk memberikan proyeksi yang lebih presisi dibandingkan pada data mentah.

G. Peramalan dengan Model Prophet



Gambar 10. Plot Hasil Prediksi Model Prophet setelah Imputasi *Outlier*

Plot menampilkan hasil peramalan 12 Bulan ke depan dari Model Prophet. Secara visual, model ini menunjukkan kemampuan yang sangat baik dalam menangkap tren jangka panjang dan pola musiman tahunan yang melekat pada data pencairan kredit, terlihat dari garis peramalan (biru tua) yang mengikuti pergerakan data historis dengan akurat. Selain itu, interval kepercayaan (area abu-abu) yang terlihat cukup sempit dan relatif stabil menunjukkan bahwa tingkat ketidakpastian dalam prediksi tergolong rendah, sehingga memperkuat kepercayaan terhadap hasil ramalan. Karakteristik ini mencerminkan kemampuan model Prophet dalam menangani pola data yang kompleks dengan baik, menjadikannya kandidat kuat untuk peramalan yang akurat.



Gambar 12. Plot Komponen Model Prophet (Tren dan Musiman Tahunan)

Plot menyajikan dekomposisi data pencairan kredit oleh Model Prophet ke dalam komponen utamanya, yaitu tren dan musiman tahunan. Plot tren di bagian atas secara jelas mengidentifikasi adanya kecenderungan kenaikan jangka panjang yang konsisten dan mulus dalam data, menunjukkan arah pertumbuhan. Sementara itu, plot musiman tahunan di bagian bawah mengungkapkan pola berulang setiap tahun, di mana bulan-bulan tertentu secara konsisten menunjukkan tingkat pencairan kredit yang lebih tinggi atau lebih rendah dari rata-rata tahunan. Analisis komponen ini memberikan wawasan yang lebih dalam mengenai dinamika yang mendasari data, membantu dalam memahami faktor-faktor yang mempengaruhi fluktuasi pencairan kredit.

H. Model Terbaik

Setelah melakukan serangkaian pemodelan deret waktu, termasuk ARIMA dan ETS pada data asli maupun setelah imputasi *outlier*, serta Model Prophet, identifikasi model terbaik didasarkan pada perbandingan metrik error utama seperti RMSE (*Root Mean Squared Error*), MAE (*Mean Absolute Error*), dan MAPE (*Mean Absolute Percentage Error*) pada data *training*. Berdasarkan hasil perbandingan:

1. Model Prophet menunjukkan kinerja terbaik dengan nilai RMSE (4.483.520), MAE (3.274.253), dan MAPE (85.11%);
2. Model ETS (setelah imputasi) berada di posisi kedua dengan RMSE (4.455.887), MAE (3.275.266), dan MAPE (88.44%);
3. Model ARIMA (setelah imputasi) menempati posisi ketiga dengan RMSE (4.876.694), MAE (3.432.408), dan MAPE (92.95%).

Secara keseluruhan, Model Prophet terbukti menjadi model yang paling unggul untuk peramalan data pencairan kredit ini. Kinerjanya yang baik terutama ditunjukkan oleh nilai MAPE yang lebih rendah dibandingkan model ARIMA dan ETS, mengindikasikan kemampuan Model Prophet yang lebih baik dalam menangkap pola tren non-linier dan musiman yang kompleks pada data, serta menghasilkan prediksi dengan akurasi yang lebih tinggi.

V. KESIMPULAN

1. Data pencairan kredit memiliki karakteristik volatil dan mengandung outlier signifikan, meskipun secara statistik telah terbukti stasioner melalui uji ADF, ACF, dan PACF.
2. Model ARIMA(0,0,0) dan ETS(M,N,M) yang diterapkan pada data mentah (sebelum imputasi) menghasilkan performa prediksi yang sangat buruk, dengan nilai MAPE yang sangat tinggi dan prediksi yang tidak mencerminkan pola data sesungguhnya.
3. Setelah dilakukan imputasi outlier dengan metode moving average, terjadi peningkatan signifikan pada stabilitas dan akurasi model, ditandai dengan penurunan nilai error prediksi.
4. Model Prophet menunjukkan performa terbaik dibanding ARIMA dan ETS setelah imputasi, dengan nilai RMSE (4.483.520), MAE (3.274.253), dan MAPE (85,11%), serta mampu menangkap pola tren jangka panjang dan musiman tahunan secara lebih akurat.
5. Secara keseluruhan, Prophet adalah model yang paling sesuai digunakan dalam peramalan data pencairan kredit pada kasus ini.

DAFTAR PUSTAKA

- Bank Indonesia. (2022). Laporan Perekonomian Indonesia 2022. Jakarta: Bank Indonesia.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control* (5th ed.). Hoboken, NJ: Wiley.
- Box, G. E. P., & Jenkins, G. M. (1976). *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day.
- Chatfield, C. (2003). *The Analysis of Time Series: An Introduction* (6th ed.). Boca Raton: CRC Press.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). Melbourne, Australia: OTexts.
- Hyndman, R. J., Koehler, A. B., Snyder, R. D., & Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, 18(3), 439–454.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688.

- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: Methods and Applications* (3rd ed.). New York: Wiley.
- Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37–45.

