

PERBANDINGAN MODEL CMAC DAN ARTIFICIAL NEURAL NETWORK TIME-DELAY UNTUK PREDIKSI RETURN SAHAM BERBASIS LOG RETURN

Muhamad Iradat Achmad^{1*}

¹Teknik Informatika, Fakultas Teknik, Universitas Dayanu Ikhsanuddin

irad4t@gmail.com

*Penulis Korespondensi

diajukan: 2 Februari 2026,

diterima: 24 Februari 2026.

Abstract

Financial time series modeling faces a fundamental challenge due to the dominance of stochastic components and short-term temporal dependence that cannot be adequately represented by static models. This study aims to compare the predictive capability of static and dynamic models in forecasting daily stock price changes based on log return transformation. The approaches examined include high-order polynomial regression as a baseline model, the Cerebellar Model Articulation Controller with explicit lag structure, and the Artificial Neural Network Time-Delay model. The dataset consists of daily observations of stock code WIFI obtained from Google Finance, covering the period from January 2, 2025 to December 30, 2025 with a total of 240 observations. Model performance is evaluated using a time-based train–test scheme to assess out-of-sample prediction accuracy through Root Mean Squared Error, coefficient of determination, and Durbin–Watson statistics. The empirical results indicate that the polynomial model fails to generalize, producing extremely large prediction errors and strongly autocorrelated residuals. In contrast, the CMAC model with explicit lag structure and the ANN Time-Delay model achieve substantially lower prediction errors and residuals that approximate a random process. The comparable performance of the two dynamic models suggests that explicit temporal memory representation plays a dominant role in improving predictive accuracy, while additional nonlinear approximation complexity provides limited benefit. This study concludes that financial time series modeling is more appropriately formulated as the estimation of a dynamic system with limited memory. The integration of explicit lag structure is shown to be essential for representing stock price dynamics more realistically.

Keywords: *financial time series, log return, CMAC, ANN Time-Delay, stock prediction*

Abstrak

Pemodelan runtun waktu finansial menghadapi tantangan utama berupa dominasi komponen stokastik dan ketergantungan temporal jangka pendek yang sulit direpresentasikan oleh model statis. Penelitian ini bertujuan membandingkan kemampuan model statis dan model dinamis dalam memprediksi perubahan harga saham harian berbasis transformasi log return. Pendekatan yang dianalisis meliputi regresi polinomial orde tinggi sebagai model baseline, Cerebellar Model Articulation Controller dengan lag eksplisit, dan Artificial Neural Network Time-Delay. Data yang digunakan adalah data harian saham kode WIFI yang diperoleh melalui Google Finance dengan periode pengamatan 2 Januari 2025 hingga 30 Desember 2025 sebanyak 240 observasi. Evaluasi dilakukan menggunakan skema train–test berbasis waktu untuk menilai performa prediksi out-of-sample melalui metrik Root Mean Squared Error, koefisien determinasi, dan statistik Durbin–Watson. Hasil penelitian menunjukkan bahwa model polinomial gagal melakukan generalisasi dengan kesalahan prediksi sangat besar dan residual yang memiliki autokorelasi kuat. Sebaliknya, model CMAC dengan lag eksplisit dan ANN Time-Delay menghasilkan kesalahan prediksi yang jauh lebih kecil serta residual yang mendekati proses acak. Kesetaraan performa antara kedua model dinamis menunjukkan bahwa representasi memori temporal merupakan faktor utama dalam peningkatan akurasi prediksi, sedangkan kompleksitas aproksimasi nonlinier memberikan kontribusi tambahan yang terbatas. Penelitian ini menyimpulkan bahwa pemodelan runtun waktu finansial lebih tepat dipahami sebagai estimasi sistem dinamis dengan memori terbatas. Integrasi struktur lag eksplisit terbukti esensial untuk merepresentasikan dinamika perubahan harga saham secara lebih realistis.

Kata kunci: *runtun waktu finansial, log return, CMAC, ANN Time-Delay, prediksi saham*

1. PENDAHULUAN

1.1 Latar Belakang

Prediksi runtun waktu (time series forecasting) memegang peran penting dalam berbagai bidang ilmu dan industri, terutama pada domain finansial di mana keputusan investasi, manajemen risiko, dan strategi perdagangan sangat bergantung pada kemampuan untuk meramalkan pergerakan pasar secara akurat (Lawal et al., 2023). Salah satu waktu seri yang paling menantang dan menarik secara akademik adalah harga saham harian, karena dinamika pasar saham mencerminkan interaksi kompleks dari berbagai faktor ekonomi, psikologi investor, dan peristiwa global yang tidak sepenuhnya deterministik (Zhang et al., 2024). Berbeda dengan sinyal fisik yang sering memiliki pola periodik atau musiman yang jelas, harga saham sering kali menunjukkan sifat nonlinieritas, volatilitas tinggi, serta ketidakstasioneran yang signifikan (Mücher, 2022).

Secara teori ekonometrik, harga saham pada umumnya mengikuti proses stokastik yang mendekati random walk, sebuah fenomena di mana perubahan harga hanya bersifat acak dan tidak dapat diprediksi secara sistematis dengan memanfaatkan informasi historis semata (Enow, 2023). Hipotesis ini dikenal luas dalam literatur ekonomi sebagai Efisiensi Pasar Versi Lemah (Weak Form Market Efficiency) (Zikova A & Vesela J, 2021). Bila hipotesis ini berlaku, maka model prediksi yang hanya menggunakan data harga masa lalu harus menghadapi tantangan besar untuk menghasilkan prediksi yang akurat secara signifikan di luar pola acak semata (Chatterjee et al., 2021). Oleh karena itu, metodologi prediksi untuk harga saham sering diarahkan kepada return saham, bukan level harga absolutnya, karena return cenderung lebih stasioner dan memiliki sifat statistik yang lebih cocok untuk dipelajari menggunakan model prediktif (McMillan, 2021).

Dalam ranah kecerdasan buatan dan pembelajaran mesin, telah dikembangkan berbagai pendekatan untuk memodelkan runtun waktu nonlinier ini (Masini et al., 2023). Model linier klasik seperti regresi polinomial sering kali tidak mampu menangkap struktur internal data finansial karena keterbatasan asumsi linearitas dan ketidakmampuannya dalam memproses dinamika temporal ketika struktur hubungan antar-lag tidak eksplisit dimasukkan (Mo, 2023). Di sisi lain, pendekatan berbasis jaringan syaraf tiruan (Artificial Neural Network, ANN), khususnya varian time-delay neural network, mampu mengakomodasi aspek dinamis dari runtun waktu melalui penggunaan informasi historis dalam bentuk lag input yang secara eksplisit mewakili nilai masa lalu sebagai fitur (Sako et al., 2022).

Selain ANN, model lain dalam literatur kecerdasan buatan seperti Cerebellar Model Articulation Controller (CMAC) juga menawarkan pendekatan nonlinier untuk mempelajari hubungan input-output yang kompleks (Nguyen et al., 2025). CMAC pada dasarnya adalah model interpolatif berbasis memori yang memiliki kemampuan generalisasi lokal, dan telah digunakan dalam berbagai aplikasi kontrol dan regresi nonlinier (Xu et al., 2021). Namun, pemanfaatan CMAC dalam konteks prediksi runtun waktu finansial masih relatif kurang diteliti, terutama ketika diterapkan dengan mekanisme lag eksplisit, sebuah pendekatan yang memungkinkan model ini untuk mempertimbangkan dinamika temporal seperti halnya yang dilakukan oleh jaringan syaraf time-delay (Lu & Wu, 2010).

Secara umum, tantangan utama dalam memodelkan data finansial seperti return saham adalah kebutuhan untuk menangkap pola nonlinier dan dinamis dari data yang sangat bising, tanpa

overfitting terhadap fluktuasi acak (Tang et al., 2021). Pendekatan yang hanya mengandalkan parameter global tanpa mekanisme memori temporal sering kali gagal menghasilkan prediksi yang robust di luar sampel (out-of-sample) (Staněk, 2023), sedangkan pendekatan yang memanfaatkan informasi historis dalam kerangka time series memiliki peluang lebih besar untuk menangkap struktur hubungan antarlag yang relevan (Bennett et al., 2021).

Berdasarkan latar belakang tersebut, penelitian ini berfokus pada perbandingan performa dua paradigma model nonlinier berbeda, yakni CMAC dengan lag eksplisit dan ANN time-delay, dalam memprediksi log return saham pada dataset harian. Selain itu, penelitian ini juga menguji model polinomial sebagai baseline deterministik guna menunjukkan batas kemampuan model statis dalam menghadapi karakteristik runtun waktu finansial. Evaluasi performa dilakukan menggunakan skema train–test berbasis waktu, serta metrik evaluasi yang mencakup Root Mean Square Error (RMSE), koefisien determinasi (R^2), dan Durbin–Watson untuk memeriksa autokorelasi residual.

1.2 Rumusan Masalah

Berdasarkan karakteristik data finansial yang bersifat nonlinier, tidak stasioner pada level harga, serta memiliki dinamika temporal yang kompleks, pemilihan model prediksi runtun waktu menjadi persoalan metodologis yang penting. Model statis dengan parameter global sering kali tidak mampu menangkap dinamika lokal data, sedangkan model nonlinier berbasis pembelajaran mesin menawarkan fleksibilitas yang lebih tinggi, namun performanya sangat bergantung pada cara representasi informasi historis dimasukkan ke dalam model.

Dalam konteks tersebut, penelitian ini merumuskan beberapa permasalahan utama sebagai berikut:

1. Bagaimana pengaruh penggunaan transformasi log return terhadap kestabilan pemodelan runtun waktu harga saham harian?
2. Apakah model nonlinier berbasis memori lokal seperti CMAC dengan mekanisme lag eksplisit mampu memberikan performa prediksi yang kompetitif dibandingkan dengan model global seperti Artificial Neural Network time-delay?
3. Sejauh mana model statis berbasis regresi polinomial mampu berfungsi sebagai baseline dalam memodelkan runtun waktu finansial yang bersifat dinamis?
4. Bagaimana perbandingan performa ketiga model dalam prediksi out-of-sample berdasarkan metrik kesalahan prediksi dan karakteristik residual?

Rumusan masalah ini diarahkan untuk menguji efektivitas representasi dinamika temporal dalam meningkatkan kemampuan prediksi pada data runtun waktu finansial.

1.3 Tujuan Penelitian

Penelitian ini bertujuan untuk mengkaji dan membandingkan efektivitas beberapa pendekatan pemodelan nonlinier dalam memprediksi return saham berbasis runtun waktu. Secara khusus, tujuan penelitian ini adalah:

1. Mengimplementasikan skema pemodelan runtun waktu berbasis transformasi log return untuk meningkatkan kestabilan statistik data finansial.
2. Mengembangkan model CMAC dengan mekanisme lag eksplisit sebagai representasi memori temporal dalam prediksi runtun waktu.

3. Mengimplementasikan model Artificial Neural Network berbasis time-delay sebagai pendekatan global dalam pembelajaran hubungan nonlinier dinamis.
4. Membandingkan performa prediksi model CMAC, ANN time-delay, dan regresi polinomial menggunakan skema evaluasi train-test berbasis waktu.
5. Mengevaluasi kualitas model berdasarkan akurasi prediksi dan karakteristik residual untuk menilai validitas pemodelan runtun waktu finansial.

Tujuan-tujuan tersebut diarahkan untuk memperoleh pemahaman empiris mengenai efektivitas model lokal dan global dalam memodelkan data finansial yang kompleks.

1.4 Kontribusi Penelitian

Penelitian ini memberikan beberapa kontribusi metodologis dan empiris dalam bidang pemodelan runtun waktu berbasis kecerdasan buatan, khususnya pada domain prediksi finansial. Kontribusi utama penelitian ini meliputi:

1. Pengembangan implementasi CMAC dengan mekanisme lag eksplisit untuk pemodelan runtun waktu finansial, yang memungkinkan representasi dinamika temporal dalam kerangka model berbasis memori lokal.
2. Penyusunan kerangka evaluasi komparatif antara model lokal (CMAC) dan model global (ANN time-delay) dalam prediksi return saham berbasis log return.
3. Penerapan skema validasi out-of-sample berbasis pembagian waktu (time series split) untuk memastikan evaluasi model yang realistis terhadap kondisi prediksi masa depan.
4. Penyediaan analisis empiris mengenai keterbatasan model statis dalam memodelkan data finansial dibandingkan dengan model dinamis berbasis pembelajaran mesin.
5. Penyajian bukti eksperimental bahwa representasi informasi historis melalui struktur lag merupakan faktor kunci dalam meningkatkan performa prediksi runtun waktu nonlinier.

Secara keseluruhan, penelitian ini berkontribusi dalam memperkaya pendekatan pemodelan data finansial dengan menyoroti peran struktur temporal dan perbandingan paradigma pembelajaran lokal dan global dalam konteks prediksi runtun waktu.

2. METODE

2.1 Data Penelitian

Data yang digunakan dalam penelitian ini merupakan runtun waktu finansial berupa harga saham harian untuk kode saham WIFI. Data diperoleh secara otomatis melalui aplikasi spreadsheet yang disediakan oleh Google, sehingga seluruh observasi bersumber langsung dari sistem agregasi data pasar yang diperbarui secara daring. Periode pengamatan dimulai pada tanggal 2 Januari 2025 dan berakhir pada tanggal 30 Desember 2025 dengan jumlah total observasi sebanyak ($N = 240$) hari perdagangan. Dengan demikian, data dapat direpresentasikan sebagai deret waktu diskret berindeks waktu $t = 1, 2, \dots, N$.

Untuk setiap waktu t , tersedia himpunan variabel pasar yang merepresentasikan dinamika harga intrahari dan aktivitas perdagangan. Vektor pengamatan pada waktu ke- t dinyatakan sebagai:

$$z_t = [O_t, H_t, L_t, C_t, V_t]^T$$

dengan O_t menyatakan harga pembukaan (open), H_t harga tertinggi (high), L_t harga terendah (low), C_t harga penutupan (close), dan V_t volume transaksi pada hari ke- t . Variabel-variabel tersebut mencerminkan informasi agregat perilaku pasar dalam satu periode perdagangan dan membentuk deret waktu multivariat yang memiliki ketergantungan temporal.

Dalam penelitian ini, fokus utama analisis diarahkan pada dinamika harga penutupan karena variabel tersebut merepresentasikan nilai konsensus pasar pada akhir sesi perdagangan. Oleh karena itu, deret waktu harga penutupan didefinisikan sebagai:

$$P_t = C_t$$

Sehingga deret harga dapat dinyatakan sebagai:

$$P_{t=1}^N = P_1, P_2, \dots, P_N$$

Sebagai runtun waktu finansial, deret harga saham umumnya menunjukkan karakteristik nonstasioner pada level harga. Secara konseptual, dinamika harga dapat dinyatakan sebagai proses stokastik diskret:

$$P_t = g(P_{t-1}, \xi_t)$$

dengan ξ_t adalah komponen gangguan acak yang merepresentasikan informasi baru yang masuk ke pasar. Ketergantungan pada nilai masa lalu menunjukkan bahwa data memiliki struktur dinamis yang relevan untuk pemodelan runtun waktu.

Observasi yang diperoleh melalui sistem agregasi data pasar memiliki interval waktu yang konsisten, yaitu satu hari perdagangan. Dengan interval sampling tetap, data membentuk proses waktu diskret berjarak seragam sehingga dapat dianalisis menggunakan kerangka pemodelan runtun waktu standar. Jika waktu kalender dinyatakan sebagai τ_t , maka pemetaan waktu diskret terhadap waktu kalender dapat dinyatakan sebagai fungsi monoton meningkat:

$$\tau_1 < \tau_2 < \dots < \tau_N$$

Konsistensi interval observasi memastikan bahwa ketergantungan temporal antar pengamatan dapat diinterpretasikan secara langsung sebagai dinamika evolusi sistem finansial.

Struktur data penelitian ini dapat dipandang sebagai realisasi dari proses stokastik multivariat:

$$\{z_t\}_{t=1}^N$$

dengan:

$$z_t \in R^5$$

Namun karena tujuan penelitian adalah pemodelan prediksi perubahan harga, maka analisis selanjutnya difokuskan pada fungsi transformasi dari deret harga penutupan menjadi deret

perubahan relatif yang lebih stabil secara statistik. Dengan demikian, data penelitian menyediakan dasar empiris untuk membangun model prediksi runtun waktu yang memanfaatkan informasi historis sebagai representasi keadaan sistem pasar.

Penggunaan data aktual pasar saham harian memberikan konteks empiris yang realistis bagi evaluasi model prediktif. Karena data bersumber dari sistem pencatatan perdagangan nyata, variasi yang muncul mencerminkan interaksi kompleks faktor ekonomi, ekspektasi investor, serta dinamika informasi pasar. Oleh karena itu, struktur data yang digunakan dalam penelitian ini menyediakan lingkungan pengujian yang relevan untuk mengevaluasi kemampuan model dalam mempelajari pola nonlinier dan ketergantungan temporal pada runtun waktu finansial.

2.2 Transformasi Data

Tahap transformasi data bertujuan mengubah deret harga penutupan saham menjadi representasi yang lebih sesuai untuk pemodelan runtun waktu prediktif. Deret harga saham pada level absolut umumnya menunjukkan kecenderungan nonstasioner, yaitu rata-rata dan varians berubah terhadap waktu, sehingga tidak memenuhi asumsi kestabilan statistik yang diperlukan oleh banyak metode pemodelan. Untuk mengatasi karakteristik tersebut, penelitian ini menggunakan transformasi log return yang mengubah perubahan harga menjadi perubahan relatif dalam skala logaritmik.

Jika P_t menyatakan harga penutupan saham pada waktu ke- t , maka log return didefinisikan sebagai selisih logaritma natural harga pada dua periode berurutan:

$$r_t = \ln(P_t) - \ln(P_{t-1})$$

Transformasi ini ekuivalen dengan logaritma rasio harga:

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right)$$

Definisi tersebut mengubah proses pertumbuhan harga yang bersifat multiplikatif menjadi proses perubahan aditif. Jika dinamika harga mengikuti proses stokastik multiplikatif:

$$P_t = P_{t-1} \cdot G_t$$

dengan G_t adalah faktor pertumbuhan acak, maka dengan mengambil logaritma diperoleh:

$$\ln(P_t) = \ln(P_{t-1}) + \ln(G_t)$$

Sehingga log return merepresentasikan komponen perubahan stokastik secara langsung:

$$r_t = \ln(G_t)$$

Transformasi ini menghasilkan representasi perubahan harga yang independen terhadap skala absolut harga. Jika harga meningkat secara eksponensial, log return tetap mempertahankan

distribusi perubahan yang relatif stabil. Dengan demikian, log return lebih sesuai untuk analisis statistik dan pemodelan prediktif dibandingkan level harga.

Salah satu sifat penting dari log return adalah aditivitas terhadap waktu. Untuk interval waktu sepanjang k periode, akumulasi log return sama dengan perubahan logaritmik total harga:

$$\sum_{i=1}^k r_{t-i+1} = \ln(P_t) - \ln(P_{t-k})$$

Sifat aditif ini memudahkan analisis perubahan harga dalam berbagai horizon waktu tanpa memerlukan transformasi tambahan. Dalam konteks pemodelan runtun waktu, aditivitas memungkinkan dinamika sistem dinyatakan sebagai fungsi dari nilai historis dalam bentuk linier terhadap waktu.

Transformasi log return juga berkaitan dengan aproksimasi perubahan relatif untuk fluktuasi kecil. Dengan menggunakan pengembangan deret Taylor pada fungsi logaritma di sekitar satu diperoleh hubungan:

$$\ln(1 + x) \approx x \quad \text{untuk } |x| \ll 1$$

Jika perubahan harga relatif kecil, maka log return mendekati return sederhana yang didefinisikan sebagai:

$$R_t = \frac{P_t - P_{t-1}}{P_{t-1}}$$

Sehingga untuk variasi harga moderat berlaku pendekatan:

$$r_t \approx R_t$$

Namun untuk perubahan harga yang lebih besar, transformasi logaritmik memberikan representasi yang lebih simetris antara kenaikan dan penurunan harga, sehingga distribusi perubahan menjadi lebih seimbang.

Dari perspektif statistik, tujuan utama transformasi adalah memperoleh deret waktu yang mendekati stasioner. Jika harga mengikuti proses random walk multiplikatif, maka log return dapat dipandang sebagai proses dengan rataan dan varians relatif konstan:

$$E(r_t) = \mu$$

$$\text{Var}(r_t) = \sigma^2$$

Kestabilan parameter statistik ini memungkinkan model prediktif mempelajari struktur dinamika tanpa terdistorsi oleh tren deterministik pada level harga.

Setelah transformasi dilakukan, deret log return membentuk runtun waktu baru:

$$\{r_t\}_{t=2}^N$$

Deret ini kemudian digunakan sebagai variabel target dalam pemodelan runtun waktu. Struktur dinamis sistem dinyatakan sebagai fungsi ketergantungan terhadap nilai masa lalu:

$$r_t = f(r_{t-1}, r_{t-2}, \dots, r_{t-p}) + \varepsilon_t$$

dengan $f(\cdot)$ merepresentasikan hubungan nonlinier yang dipelajari oleh model dan ε_t adalah komponen gangguan acak.

Transformasi log return pada akhirnya berfungsi sebagai pemetaan dari ruang harga positif menuju ruang bilangan riil yang lebih stabil secara statistik. Dengan menghilangkan efek skala harga, mengubah dinamika multiplikatif menjadi aditif, serta meningkatkan kestasioneran deret waktu, transformasi ini menyediakan representasi matematis yang lebih sesuai untuk pemodelan runtun waktu finansial berbasis pembelajaran mesin.

2.3 Skema Train–Test Time Series

Evaluasi model prediktif pada data runtun waktu memerlukan prosedur pembagian data yang mempertahankan urutan temporal observasi. Berbeda dengan pembagian acak pada data independen, runtun waktu memiliki ketergantungan antar pengamatan sehingga informasi masa depan tidak boleh digunakan dalam proses pelatihan model. Oleh karena itu, penelitian ini menggunakan skema pembagian berbasis waktu yang memisahkan data historis sebagai himpunan pelatihan dan data setelahnya sebagai himpunan pengujian.

Misalkan deret log return yang telah diperoleh dari transformasi harga dinyatakan sebagai berikut.

$$\{r_t\}_{t=1}^N$$

dengan N adalah jumlah total observasi. Himpunan data dibagi pada suatu indeks waktu T sehingga:

$$\mathcal{D}_{train} = \{r_1, r_2, \dots, r_T\}$$

$$\mathcal{D}_{test} = \{r_{T+1}, r_{T+2}, \dots, r_N\}$$

Pembagian ini memastikan bahwa seluruh proses pembelajaran parameter model hanya menggunakan informasi yang tersedia hingga waktu T . Dengan demikian, evaluasi model mencerminkan kondisi prediksi nyata di mana nilai masa depan tidak diketahui pada saat pelatihan.

Dalam pemodelan runtun waktu dengan struktur lag, setiap prediksi didasarkan pada vektor keadaan historis. Jika panjang memori temporal dinyatakan sebagai p , maka vektor input pada waktu t didefinisikan sebagai:

$$x_t = [r_{t-1}, r_{t-2}, \dots, r_{t-p}]^T$$

Tujuan model adalah membentuk pemetaan prediktif:

$$\hat{r}_t = f(x_t)$$

dengan $f(\cdot)$ adalah fungsi aproksimasi yang dipelajari dari data pelatihan.

Setelah parameter model diestimasi menggunakan himpunan pelatihan, performa model dievaluasi pada himpunan pengujian melalui prediksi satu langkah ke depan secara berurutan. Prosedur ini dikenal sebagai prediksi out-of-sample karena data pengujian tidak digunakan dalam proses estimasi parameter. Untuk setiap waktu $t > T$, prediksi dihitung berdasarkan informasi historis yang tersedia hingga waktu $t - 1$:

$$\hat{r}_t = f(r_{t-1}, r_{t-2}, \dots, r_{t-p})$$

Kesalahan prediksi pada periode pengujian dinyatakan sebagai:

$$e_t = r_t - \hat{r}_t$$

untuk $t = T + 1, T + 2, \dots, N$.

Struktur evaluasi ini memberikan estimasi kemampuan generalisasi model terhadap data yang tidak pernah diamati sebelumnya.

Dalam implementasi prediksi runtun waktu, prosedur yang digunakan bersifat rekursif satu langkah ke depan. Jika model memerlukan nilai historis yang berada dalam himpunan pengujian, maka nilai aktual yang telah diamati digunakan sebagai bagian dari vektor input. Dengan demikian, prediksi pada waktu t selalu menggunakan informasi terbaru yang tersedia hingga waktu tersebut. Secara matematis, untuk setiap waktu pengujian berlaku:

$$x_t = [r_{t-1}, r_{t-2}, \dots, r_{t-p}]^T$$

dengan komponen vektor dapat berasal dari himpunan pelatihan maupun pengujian sepanjang nilai tersebut telah terealisasi sebelum waktu prediksi.

Tujuan utama skema ini adalah mengestimasi nilai harapan kondisional return masa depan berdasarkan informasi historis yang tersedia pada saat prediksi:

$$\hat{r}_t = E(r_t | \mathcal{F}_{t-1})$$

dengan \mathcal{F}_{t-1} menyatakan himpunan informasi yang diketahui hingga waktu $t - 1$. Pendekatan ini sejalan dengan prinsip prediksi dalam sistem dinamis di mana struktur ketergantungan temporal dipertahankan secara eksplisit.

Skema pembagian berbasis waktu juga memungkinkan interpretasi statistik yang konsisten terhadap residual prediksi. Jika model mampu menangkap struktur dinamika sistem, maka deret residual pada periode pengujian akan mendekati proses acak dengan rata-rata mendekati nol:

$$E(e_t) \approx 0$$

dan tanpa autokorelasi signifikan antar waktu:

$$\text{Cov}(e_t, e_{t-k}) \approx 0 \quad \text{untuk } k \neq 0$$

Kondisi ini menunjukkan bahwa model telah mengekstraksi informasi prediktif yang tersedia dalam data historis dan tidak menyisakan pola sistematis pada kesalahan prediksi.

Dengan mempertahankan urutan temporal data, menggunakan prediksi satu langkah ke depan, serta mengevaluasi performa pada data yang benar-benar tidak terlihat selama pelatihan, skema train–test berbasis runtun waktu menyediakan kerangka evaluasi yang realistis bagi kemampuan model dalam mempelajari dinamika sistem finansial dan melakukan generalisasi terhadap kondisi masa depan.

2.4 Model Polinomial

Model polinomial digunakan sebagai pendekatan baseline untuk memetakan hubungan deterministik antara variabel input dan target pada runtun waktu. Dalam kerangka regresi, model ini merepresentasikan fungsi aproksimasi sebagai kombinasi linier dari basis polinomial terhadap variabel penjelas. Jika suatu variabel input dinyatakan sebagai x_t dan variabel target sebagai y_t , maka model polinomial orde m dinyatakan sebagai:

$$\hat{y}_t = \beta_0 + \beta_1 x_t + \beta_2 x_t^2 + \dots + \beta_m x_t^m$$

dengan $\beta_0, \beta_1, \dots, \beta_m$ adalah parameter model yang diestimasi dari data. Struktur ini merupakan pemetaan global karena seluruh parameter mempengaruhi prediksi pada setiap titik input.

Dalam konteks pemodelan runtun waktu finansial, variabel target yang digunakan adalah log return r_t . Model polinomial membentuk hubungan deterministik antara indeks waktu atau variabel input yang direpresentasikan sebagai x_t dan nilai return. Dengan demikian, model prediktif dinyatakan sebagai:

$$\hat{r}_t = \sum_{k=0}^m \beta_k x_t^k$$

Jika seluruh pengamatan dinyatakan dalam bentuk vektor, maka sistem regresi dapat dituliskan dalam bentuk matriks. Misalkan terdapat n observasi pelatihan, maka vektor target didefinisikan sebagai:

$$y = \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_n \end{bmatrix}$$

Matriks desain polinomial orde m dinyatakan sebagai:

$$A = \begin{bmatrix} 1 & x_1 & x_1^2 & \cdots & x_1^m \\ 1 & x_2 & x_2^2 & \cdots & x_2^m \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & x_n^2 & \cdots & x_n^m \end{bmatrix}$$

Vektor parameter model dinyatakan sebagai:

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_m \end{bmatrix}$$

Sehingga model regresi dapat ditulis dalam bentuk linier terhadap parameter:

$$y = A\beta + \varepsilon$$

dengan ε adalah vektor kesalahan prediksi. Estimasi parameter dilakukan dengan meminimalkan jumlah kuadrat kesalahan:

$$J(\beta) = (y - A\beta)^T (y - A\beta)$$

Solusi optimum diperoleh dari kondisi turunan pertama sama dengan nol yang menghasilkan persamaan normal:

$$A^T A \beta = A^T y$$

Jika matriks $A^T A$ bersifat invertibel, maka parameter dapat dihitung sebagai:

$$\beta = (A^T A)^{-1} A^T y$$

Model polinomial merupakan aproksimasi fungsi global karena setiap parameter berkontribusi terhadap seluruh domain input. Sifat ini berbeda dari model berbasis memori lokal yang hanya menyesuaikan parameter pada wilayah tertentu ruang input. Dalam interpretasi geometris, model polinomial membentuk permukaan aproksimasi kontinu yang meminimalkan kesalahan kuadrat terhadap data pelatihan.

Dalam kerangka runtun waktu, model polinomial dapat dipandang sebagai aproksimasi fungsi deterministik dari variabel penjelas terhadap nilai return:

$$r_t = f(x_t) + \varepsilon_t$$

dengan fungsi aproksimasi berbentuk polinomial:

$$f(x_t) = \sum_{k=0}^m \beta_k x_t^k$$

Kesalahan prediksi pada waktu t dinyatakan sebagai:

$$e_t = r_t - \hat{r}_t$$

Jika model mampu merepresentasikan pola sistematis dalam data, maka residual diharapkan memiliki rata-rata mendekati nol dan tidak menunjukkan pola deterministik terhadap waktu.

Dalam penelitian ini, model polinomial digunakan sebagai baseline matematis untuk mengevaluasi kemampuan model statis dalam memodelkan dinamika runtun waktu finansial. Karena struktur model tidak memasukkan mekanisme memori temporal eksplisit, kemampuan prediksi sepenuhnya bergantung pada bentuk fungsi global yang diestimasi dari data pelatihan. Dengan demikian, model ini menyediakan titik referensi untuk membandingkan efektivitas pendekatan nonlinier dinamis yang memanfaatkan informasi historis melalui struktur lag.

2.5 Model CMAC dengan Lag Eksplisit

Cerebellar Model Articulation Controller merupakan arsitektur jaringan berbasis memori asosiatif yang memetakan ruang input kontinu ke dalam representasi diskret melalui mekanisme kuantisasi dan aktivasi lokal. Prinsip dasar model ini adalah melakukan aproksimasi fungsi nonlinier dengan menjumlahkan bobot-bobot lokal yang diaktifkan oleh suatu vektor input. Berbeda dengan model global seperti regresi polinomial, CMAC membentuk pemetaan lokal sehingga perubahan parameter hanya mempengaruhi wilayah terbatas dalam ruang input.

Dalam pemodelan runtun waktu finansial, struktur dinamis sistem direpresentasikan melalui vektor lag eksplisit dari log return. Jika r_t menyatakan log return pada waktu ke- t , maka vektor input didefinisikan sebagai:

$$\mathbf{x}_t = \begin{bmatrix} r_{t-1} \\ r_{t-2} \\ \vdots \\ r_{t-p} \end{bmatrix}$$

dengan p adalah orde lag yang menentukan kedalaman memori temporal model. Dengan demikian, prediksi pada waktu t dinyatakan sebagai fungsi nonlinier dari nilai historis:

$$\hat{r}_t = f(x_t)$$

CMAC mengaproksimasi fungsi tersebut melalui mekanisme aktivasi lokal pada ruang input yang telah dikuantisasi. Setiap komponen vektor input dipetakan ke indeks diskret melalui proses kuantisasi seragam. Jika $x_{t,j}$ adalah komponen ke- j dari vektor input, maka indeks kuantisasi dinyatakan sebagai:

$$q_{t,j} = \left\lfloor \frac{x_{t,j} - x_j^{\min}}{\Delta_j} \right\rfloor$$

dengan Δ_j adalah resolusi kuantisasi pada dimensi ke- j , dan x_j^{\min} adalah batas bawah domain input.

Untuk setiap vektor input, CMAC tidak hanya mengaktifkan satu lokasi memori, tetapi sejumlah lokasi yang saling tumpang tindih untuk menghasilkan kemampuan generalisasi lokal. Jika jumlah lapisan asosiasi dinyatakan sebagai A , maka setiap input menghasilkan himpunan indeks memori aktif:

$$\mathcal{M}(x_t) = \{m_1, m_2, \dots, m_A\}$$

Setiap indeks memori memiliki bobot yang disimpan dalam vektor parameter model:

$$\mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_M \end{bmatrix}$$

dengan M adalah jumlah total sel memori. Prediksi CMAC diperoleh dengan menjumlahkan bobot yang diaktifkan oleh input:

$$\hat{r}_t = \sum_{m \in \mathcal{M}(x_t)} w_m$$

Persamaan ini menunjukkan bahwa fungsi aproksimasi CMAC bersifat piecewise constant pada ruang input yang telah dikuantisasi, namun menjadi halus secara global karena adanya tumpang tindih aktivasi.

Proses pelatihan CMAC bertujuan meminimalkan kesalahan prediksi antara nilai aktual dan estimasi model. Jika kesalahan pada waktu t dinyatakan sebagai:

$$e_t = r_t - \hat{r}_t$$

maka pembaruan bobot dilakukan hanya pada sel memori yang aktif. Dengan menggunakan aturan pembelajaran gradien sederhana, bobot diperbarui sebagai:

$$w_m^{(k+1)} = w_m^{(k)} + \eta \frac{e_t}{A} \quad \text{untuk setiap } m \in \mathcal{M}(x_t)$$

dengan η adalah laju pembelajaran dan k menyatakan iterasi pelatihan. Pembagian kesalahan terhadap jumlah aktivasi memastikan kontribusi pembaruan terdistribusi merata pada seluruh sel memori yang terlibat dalam prediksi.

Dalam kerangka sistem dinamis, model CMAC dengan lag eksplisit dapat dipandang sebagai aproksimasi nonlinier terhadap fungsi transisi keadaan:

$$r_t = f(r_{t-1}, r_{t-2}, \dots, r_{t-p}) + \varepsilon_t$$

dengan $f(\cdot)$ direpresentasikan oleh struktur memori lokal CMAC. Representasi ini memungkinkan model menangkap hubungan nonlinier antara perubahan harga saat ini dan pola historisnya.

Sifat penting dari CMAC adalah kemampuan generalisasi lokal. Jika dua vektor input berada pada wilayah ruang yang berdekatan, maka sebagian indeks memori yang diaktifkan akan sama. Secara matematis, untuk dua input x_a dan x_b yang berdekatan berlaku:

$$|\mathcal{M}(x_a) \cap \mathcal{M}(x_b)| > 0$$

Akibatnya, prediksi model berubah secara gradual terhadap perubahan input, sehingga mengurangi sensitivitas terhadap noise.

Dalam implementasi prediksi runtun waktu, model dilatih menggunakan data pelatihan yang disusun secara kronologis. Setelah parameter bobot diperoleh, prediksi out-of-sample dilakukan secara rekursif dengan menggunakan nilai historis yang tersedia. Struktur lag eksplisit memastikan bahwa dinamika temporal direpresentasikan langsung dalam ruang input, bukan diinternalisasi secara implisit dalam parameter model.

Model CMAC dengan lag eksplisit pada akhirnya merupakan sistem aproksimasi nonlinier berbasis memori yang menggabungkan representasi temporal eksplisit dengan mekanisme generalisasi lokal. Kombinasi ini memungkinkan model mempelajari pola nonlinier pada runtun waktu finansial dengan kompleksitas komputasi yang relatif rendah serta kemampuan adaptasi terhadap struktur data yang berubah terhadap waktu.

2.6 Model ANN Time-Delay

Model Artificial Neural Network Time-Delay merupakan perluasan dari jaringan saraf tiruan feedforward yang secara eksplisit memasukkan informasi historis runtun waktu sebagai bagian dari vektor input. Dalam konteks prediksi runtun waktu finansial, pendekatan ini memodelkan dinamika sistem sebagai pemetaan nonlinier dari sejumlah nilai masa lalu menuju nilai saat ini. Struktur ini memungkinkan jaringan menangkap ketergantungan temporal tanpa memerlukan komponen rekursif internal.

Jika r_t menyatakan log return pada waktu ke- t , maka vektor input jaringan dibentuk dari nilai historis sepanjang p periode sebelumnya sebagai berikut:

$$\mathbf{x}_t = \begin{bmatrix} r_{t-1} \\ r_{t-2} \\ \vdots \\ r_{t-p} \end{bmatrix}$$

Dengan demikian, prediksi log return pada waktu t dinyatakan sebagai fungsi nonlinier:

$$\hat{r}_t = F(x_t; \Theta)$$

dengan Θ menyatakan seluruh parameter jaringan yang meliputi bobot dan bias.

Arsitektur jaringan terdiri dari satu lapisan tersembunyi dengan H neuron. Transformasi pada lapisan tersembunyi dinyatakan sebagai:

$$h_t = \phi(W_1 x_t + b_1)$$

dengan

$W_1 \in R^{H \times p}$ adalah matriks bobot input,

$b_1 \in R^H$ adalah vektor bias,

$\phi(\cdot)$ adalah fungsi aktivasi nonlinier.

Dalam penelitian ini digunakan fungsi aktivasi hiperbolik tangens:

$$\phi(z) = \tanh(z)$$

yang memiliki turunan:

$$\phi'(z) = 1 - \tanh^2(z)$$

Fungsi aktivasi ini bersifat antisimetri dan memetakan input ke interval terbatas, sehingga meningkatkan stabilitas numerik pada proses pelatihan.

Keluaran jaringan diperoleh melalui transformasi linear dari lapisan tersembunyi:

$$\hat{r}_t = W_2 h_t + b_2$$

dengan

$W_2 \in R^{1 \times H}$ adalah bobot keluaran, dan

$b_2 \in R$ adalah bias keluaran.

Dengan menggabungkan seluruh komponen, model ANN Time-Delay merepresentasikan pemetaan nonlinier berikut:

$$\hat{r}_t = W_2 \phi(W_1 x_t + b_1) + b_2$$

Model ini merupakan aproksimator universal untuk fungsi kontinu pada domain kompak, sehingga mampu memodelkan hubungan nonlinier kompleks antara nilai historis dan nilai masa depan runtun waktu.

Parameter jaringan diperoleh melalui minimisasi fungsi kerugian kuadrat rata-rata terhadap data pelatihan. Jika terdapat N sampel pelatihan, maka fungsi kerugian dinyatakan sebagai:

$$\mathcal{L}(\Theta) = \frac{1}{N} \sum_{t=1}^N (r_t - \hat{r}_t)^2$$

Proses pelatihan menggunakan metode penurunan gradien berbasis propagasi balik kesalahan. Untuk setiap sampel pelatihan, kesalahan prediksi didefinisikan sebagai:

$$e_t = \hat{r}_t - r_t$$

Gradien terhadap parameter lapisan keluaran diberikan oleh:

$$\frac{\partial \mathcal{L}}{\partial W_2} = \frac{1}{N} \sum_{t=1}^N e_t \mathbf{h}_t^T$$

$$\frac{\partial \mathcal{L}}{\partial b_2} = \frac{1}{N} \sum_{t=1}^N e_t$$

Gradien terhadap parameter lapisan tersembunyi diperoleh melalui aturan rantai:

$$\delta_t = (W_2^T e_t) \odot \phi'(W_1 x_t + b_1)$$

$$\frac{\partial \mathcal{L}}{\partial W_1} = \frac{1}{N} \sum_{t=1}^N \delta_t \mathbf{x}_t^T$$

$$\frac{\partial \mathcal{L}}{\partial b_1} = \frac{1}{N} \sum_{t=1}^N \delta_t$$

dengan simbol \odot menyatakan perkalian elemen-sepadan.

Pembaruan parameter dilakukan menggunakan aturan gradien:

$$\Theta^{(k+1)} = \Theta^{(k)} - \eta \nabla \mathcal{L}(\Theta^{(k)})$$

dengan η adalah laju pembelajaran.

Dalam kerangka pemodelan runtun waktu, ANN Time-Delay mengaproksimasi fungsi transisi stokastik sistem:

$$r_t = F(r_{t-1}, r_{t-2}, \dots, r_{t-p}) + \varepsilon_t$$

dengan ε_t adalah komponen acak yang tidak dapat diprediksi. Representasi nonlinier ini memungkinkan jaringan menangkap pola ketergantungan jangka pendek, efek nonlinier, dan interaksi kompleks antar lag.

Sebelum pelatihan, data input dan target dinormalisasi ke interval terbatas untuk meningkatkan stabilitas optimisasi. Jika z adalah variabel yang dinormalisasi, maka transformasi linier dinyatakan sebagai:

$$z = \frac{x - x_{min}}{x_{max} - x_{min}}$$

setelah prediksi diperoleh, dilakukan transformasi balik untuk mengembalikan skala asli data.

Dalam tahap prediksi out-of-sample, jaringan menerima vektor lag yang berasal dari data historis aktual atau prediksi sebelumnya. Dengan demikian, ANN Time-Delay berfungsi sebagai model dinamis nonlinier yang memanfaatkan struktur temporal eksplisit melalui representasi input berbasis lag.

Secara konseptual, model ini memadukan representasi memori eksplisit dari sistem dinamis dengan kemampuan aproksimasi nonlinier jaringan saraf, sehingga memberikan kerangka yang fleksibel untuk memodelkan perubahan harga saham yang bersifat kompleks, nonlinier, dan tidak stasioner.

2.7 Metrik Evaluasi

Evaluasi kinerja model prediksi runtun waktu dalam penelitian ini dilakukan melalui pengukuran kesalahan prediksi, kemampuan penjelasan variasi data, serta karakteristik dependensi residual. Pengukuran dilakukan secara out-of-sample untuk menilai kemampuan generalisasi model terhadap data yang tidak digunakan pada tahap pelatihan. Misalkan y_t menyatakan nilai aktual log return pada waktu ke- t , dan \hat{y}_t menyatakan nilai prediksi model pada waktu yang sama. Banyaknya observasi pada data pengujian dinyatakan sebagai N .

Kesalahan prediksi pada setiap waktu didefinisikan sebagai selisih antara nilai aktual dan nilai estimasi:

$$e_t = y_t - \hat{y}_t$$

Ukuran utama yang digunakan untuk menilai akurasi prediksi adalah Root Mean Squared Error. Metrik ini mengukur besar deviasi rata-rata prediksi terhadap nilai aktual dalam satuan yang sama dengan variabel yang diprediksi. RMSE didefinisikan sebagai:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N e_t^2}$$

Nilai RMSE yang lebih kecil menunjukkan bahwa model menghasilkan prediksi yang lebih dekat dengan data aktual. Karena menggunakan kuadrat kesalahan, metrik ini memberikan penalti lebih besar terhadap kesalahan yang ekstrem, sehingga sensitif terhadap outlier.

Kemampuan model dalam menjelaskan variasi data diukur menggunakan koefisien determinasi. Koefisien ini membandingkan jumlah variasi yang tidak dapat dijelaskan oleh model terhadap total variasi data aktual. Total variasi data dinyatakan sebagai:

$$S_{\text{tot}} = \sum_{t=1}^N (y_t - \bar{y})^2$$

dengan \bar{y} adalah rata-rata nilai aktual pada data pengujian:

$$\bar{y} = \frac{1}{N} \sum_{t=1}^N y_t$$

Variasi residual yang tidak dapat dijelaskan model dinyatakan sebagai:

$$S_{\text{res}} = \sum_{t=1}^N e_t^2$$

Koefisien determinasi dinyatakan sebagai:

$$R^2 = 1 - \frac{S_{\text{res}}}{S_{\text{tot}}}$$

Nilai R^2 menunjukkan proporsi variasi data yang dapat dijelaskan oleh model. Nilai mendekati satu menunjukkan kecocokan model yang tinggi, sedangkan nilai negatif menunjukkan bahwa model memiliki kinerja lebih buruk dibandingkan prediktor rata-rata.

Untuk model dengan jumlah parameter yang berbeda, digunakan koefisien determinasi tersesuaikan yang memperhitungkan kompleksitas model. Jika jumlah parameter model dinyatakan sebagai k , maka koefisien determinasi tersesuaikan diberikan oleh:

$$R_{\text{adj}}^2 = 1 - (1 - R^2) \frac{N - 1}{N - k}$$

Metrik ini memberikan penalti terhadap model yang menggunakan parameter berlebih tanpa peningkatan kemampuan prediksi yang signifikan. Dengan demikian, nilai R_{adj}^2 lebih representatif untuk membandingkan model dengan kompleksitas berbeda.

Selain akurasi prediksi, karakteristik dependensi residual juga dianalisis menggunakan statistik Durbin–Watson. Statistik ini mengukur tingkat autokorelasi orde pertama pada residual prediksi. Nilai Durbin–Watson dinyatakan sebagai:

$$DW = \frac{\sum_{t=2}^N (e_t - e_{t-1})^2}{\sum_{t=1}^N e_t^2}$$

Nilai DW berada pada interval $[0, 4]$. Nilai mendekati dua menunjukkan bahwa residual tidak memiliki autokorelasi, yang berarti kesalahan prediksi bersifat acak. Nilai yang jauh lebih kecil dari dua menunjukkan adanya autokorelasi positif, sedangkan nilai yang jauh lebih besar dari dua menunjukkan autokorelasi negatif.

Dalam konteks prediksi runtun waktu finansial, residual yang tidak berkorelasi merupakan indikasi bahwa model telah menangkap struktur informasi yang tersedia dalam data historis. Sebaliknya, autokorelasi residual menunjukkan bahwa masih terdapat pola temporal yang belum dimodelkan secara memadai.

Secara keseluruhan, kombinasi RMSE, koefisien determinasi, koefisien determinasi tersesuaikan, dan statistik Durbin–Watson memberikan kerangka evaluasi yang komprehensif. RMSE mengukur ketepatan numerik prediksi, koefisien determinasi mengukur kemampuan penjelasan variasi data, koefisien determinasi tersesuaikan mengontrol kompleksitas model, dan Durbin–Watson menilai kualitas struktur residual. Pendekatan evaluasi multidimensi ini memastikan bahwa penilaian kinerja model tidak hanya didasarkan pada akurasi prediksi, tetapi juga pada konsistensi statistik dan validitas dinamika model terhadap karakteristik runtun waktu finansial.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Prediksi Out-of-Sample

Evaluasi performa model dilakukan menggunakan data pengujian yang tidak terlibat dalam proses pelatihan untuk menilai kemampuan generalisasi terhadap dinamika pasar yang tidak diamati sebelumnya. Seluruh model dilatih menggunakan data historis pada periode pelatihan dan kemudian digunakan untuk menghasilkan prediksi log return pada periode pengujian secara kronologis. Kinerja model dibandingkan berdasarkan kesalahan prediksi, kemampuan penjelasan variasi data, serta struktur dependensi residual. Hasil perbandingan ketiga metode diperlihatkan dalam Tabel 1.

Tabel 1 Hasil Perbandingan kinerja ketiga model

Poly-10	: RMSE=120.120556	R2=-1198135.6491	DW=0.0067
CMAC	: RMSE=0.110898	R2=-0.0212	DW=2.4654
ANN-TD	: RMSE=0.111146	R2=-0.0258	DW=2.4838

Hasil evaluasi Tabel 1 menunjukkan bahwa model regresi polinomial orde sepuluh menghasilkan kesalahan prediksi yang sangat besar dengan nilai Root Mean Squared Error sebesar 120.120556. Koefisien determinasi yang diperoleh bernilai negatif sangat besar, yaitu -1198135.6491 , yang menunjukkan bahwa model tidak mampu merepresentasikan hubungan antara variabel historis dan nilai masa depan pada data pengujian. Nilai statistik Durbin–Watson sebesar 0.0067 menunjukkan adanya autokorelasi positif yang sangat kuat pada residual, yang mengindikasikan bahwa struktur temporal utama pada runtun waktu tidak berhasil ditangkap oleh model statis berbasis aproksimasi global tersebut.

Model CMAC dengan lag eksplisit menunjukkan peningkatan performa yang signifikan dibandingkan model polinomial. Nilai RMSE yang diperoleh sebesar 0.110898 menunjukkan kesalahan prediksi yang jauh lebih kecil pada skala log return. Koefisien determinasi sebesar -0.0212 menunjukkan bahwa meskipun kemampuan penjelasan variasi data masih terbatas, model telah menghasilkan prediksi yang secara numerik mendekati nilai aktual. Statistik Durbin–Watson sebesar 2.4654 menunjukkan bahwa residual prediksi tidak memiliki autokorelasi positif yang kuat dan mendekati karakteristik proses acak, yang menandakan bahwa struktur dinamika utama pada data telah direpresentasikan secara memadai oleh model.

Model Artificial Neural Network Time-Delay menghasilkan performa yang sebanding dengan model CMAC. Nilai RMSE yang diperoleh sebesar 0.111146 menunjukkan tingkat kesalahan prediksi yang hampir identik dengan model CMAC. Koefisien determinasi sebesar -0.0258 menunjukkan bahwa kemampuan penjelasan variasi data relatif setara dengan model CMAC pada data pengujian. Statistik Durbin–Watson sebesar 2.4838 menunjukkan bahwa residual prediksi bersifat tidak berkorelasi secara signifikan, yang mengindikasikan bahwa model telah berhasil menangkap pola temporal utama dalam runtun waktu log return.

Secara keseluruhan, hasil prediksi out-of-sample menunjukkan perbedaan kinerja yang jelas antara model statis dan model dinamis. Model berbasis struktur lag eksplisit, baik melalui mekanisme memori lokal pada CMAC maupun aproksimasi nonlinier pada jaringan saraf, menghasilkan kesalahan prediksi yang jauh lebih kecil serta residual yang mendekati proses acak. Sebaliknya, model polinomial yang tidak mengakomodasi dinamika temporal menunjukkan kegagalan dalam merepresentasikan perilaku runtun waktu finansial pada data pengujian. Temuan ini menegaskan bahwa representasi memori temporal merupakan komponen penting dalam pemodelan perubahan harga saham berbasis data historis.

3.2 Analisis Performa Model

Perbandingan performa model pada prediksi out-of-sample menunjukkan perbedaan mendasar antara pendekatan pemodelan statis dan dinamis dalam merepresentasikan runtun waktu finansial. Hasil empiris memperlihatkan bahwa model regresi polinomial orde tinggi mengalami kegagalan generalisasi yang sangat signifikan, sedangkan model yang mengintegrasikan struktur memori temporal melalui lag eksplisit mampu menghasilkan prediksi yang jauh lebih stabil dan realistis.

Kegagalan model polinomial dapat dipahami dari sifat dasar aproksimasi global yang digunakan. Model polinomial mengasumsikan bahwa hubungan antara variabel historis dan nilai

masa depan dapat direpresentasikan oleh fungsi deterministik dengan struktur tetap pada seluruh domain data. Secara matematis, model ini mengaproksimasi hubungan sebagai:

$$y_t = \beta_0 + \beta_1 x_t + \beta_2 x_t^2 + \dots + \beta_d x_t^d + \varepsilon_t$$

Struktur ini tidak mengandung representasi memori temporal eksplisit terhadap nilai masa lalu runtun waktu. Pada data finansial yang bersifat nonstasioner dan didominasi fluktuasi acak, asumsi hubungan global semacam ini menyebabkan model sangat sensitif terhadap variasi lokal dan menghasilkan kesalahan prediksi ekstrem pada data pengujian. Nilai koefisien determinasi yang sangat negatif menunjukkan bahwa aproksimasi global tidak hanya gagal menangkap dinamika sistem, tetapi juga menghasilkan prediksi yang secara statistik lebih buruk daripada prediksi rata-rata konstan. Dengan demikian, kegagalan model polinomial tidak hanya bersifat numerik, tetapi juga konseptual, karena struktur model tidak sesuai dengan karakter proses stokastik yang mendasari perubahan harga saham.

Sebaliknya, model CMAC dan ANN Time-Delay menunjukkan performa yang hampir identik, yang mengindikasikan bahwa kedua pendekatan tersebut berhasil menangkap komponen prediktif yang tersedia dalam data. Kedua model ini memiliki kesamaan fundamental, yaitu representasi eksplisit terhadap struktur lag runtun waktu. Dalam kerangka sistem dinamis, hubungan prediktif direpresentasikan sebagai:

$$r_t = f(r_{t-1}, r_{t-2}, \dots, r_{t-p}) + \varepsilon_t$$

Representasi ini memungkinkan model memanfaatkan informasi historis jangka pendek sebagai basis prediksi. Hasil empiris menunjukkan bahwa struktur memori temporal merupakan faktor utama yang menentukan peningkatan performa model, bukan semata-mata kompleksitas nonlinier.

Model CMAC merepresentasikan fungsi prediksi melalui pemetaan lokal berbasis memori diskret. Struktur ini menghasilkan aproksimasi nonlinier berbasis wilayah yang bersifat adaptif terhadap perubahan lokal dalam ruang input. Prediksi model dinyatakan sebagai superposisi bobot lokal:

$$\hat{r}_t = \sum_{m \in \mathcal{M}(x_t)} w_m$$

Pendekatan ini memberikan kemampuan generalisasi lokal yang kuat, sehingga perubahan kecil pada input tidak menghasilkan perubahan prediksi yang tidak proporsional. Stabilitas prediksi yang dihasilkan CMAC mencerminkan efektivitas mekanisme generalisasi lokal dalam menghadapi noise tinggi pada data finansial.

Model ANN Time-Delay menggunakan aproksimasi nonlinier global melalui komposisi transformasi linear dan fungsi aktivasi nonlinier:

$$\hat{r}_t = W_2 \phi(W_1 x_t + b_1) + b_2$$

Kemampuan jaringan saraf dalam mempelajari representasi nonlinier kompleks memungkinkan model menangkap interaksi antar lag yang tidak dapat direpresentasikan oleh model linier. Namun, hasil empiris menunjukkan bahwa keunggulan fleksibilitas fungsional ANN tidak menghasilkan peningkatan performa yang signifikan dibandingkan CMAC. Hal ini mengindikasikan bahwa struktur prediktif pada log return bersifat lemah dan didominasi oleh dinamika jangka pendek sederhana, sehingga kompleksitas model yang lebih tinggi tidak memberikan keuntungan tambahan yang substansial.

Kesetaraan performa antara CMAC dan ANN memberikan implikasi metodologis penting. Dalam sistem dengan struktur prediktif lemah, keberadaan memori temporal eksplisit lebih menentukan daripada kapasitas aproksimasi nonlinier global. Dengan kata lain, keberhasilan model lebih bergantung pada kemampuan merepresentasikan dinamika waktu daripada kompleksitas fungsi aproksimasi.

Peran struktur lag dalam meningkatkan performa model dapat dijelaskan melalui konsep dependensi temporal terbatas. Jika log return mengikuti proses stokastik dengan memori jangka pendek, maka informasi prediktif yang tersedia pada waktu t terkandung dalam himpunan terbatas observasi historis. Dengan demikian, pemetaan:

$$x_t = (r_{t-1}, r_{t-2}, \dots, r_{t-p})$$

berfungsi sebagai representasi keadaan sistem yang cukup untuk menghasilkan prediksi optimal dalam kerangka informasi yang tersedia. Model yang tidak memasukkan representasi keadaan ini tidak mampu memanfaatkan struktur temporal data.

Hasil empiris juga menunjukkan bahwa peningkatan kompleksitas model tidak secara otomatis meningkatkan performa prediksi. Baik CMAC maupun ANN memiliki kapasitas aproksimasi nonlinier, namun kesalahan prediksi yang dihasilkan hampir identik. Temuan ini konsisten dengan karakteristik runtun waktu finansial yang sering diasosiasikan dengan efisiensi informasi jangka pendek, di mana komponen deterministik yang dapat dipelajari relatif kecil dibandingkan komponen acak.

Secara keseluruhan, analisis performa model menunjukkan bahwa keberhasilan pemodelan runtun waktu finansial tidak ditentukan oleh kompleksitas fungsi aproksimasi semata, tetapi oleh kesesuaian struktur model dengan sifat dinamis data. Model statis berbasis aproksimasi global tidak mampu merepresentasikan dinamika temporal, sedangkan model dengan lag eksplisit mampu menangkap komponen prediktif terbatas yang tersedia. Temuan ini menegaskan bahwa integrasi memori temporal merupakan elemen esensial dalam pemodelan prediksi perubahan harga saham berbasis data historis.

3.3 Analisis Residual

Analisis residual dilakukan untuk menilai apakah model prediksi telah menangkap struktur sistematis yang terkandung dalam runtun waktu log return atau masih menyisakan pola temporal yang belum dimodelkan. Dalam kerangka pemodelan runtun waktu, residual tidak hanya

merepresentasikan kesalahan prediksi numerik, tetapi juga berfungsi sebagai indikator apakah informasi historis telah dimanfaatkan secara optimal oleh model.

Residual pada waktu ke- t didefinisikan sebagai selisih antara nilai aktual dan nilai prediksi:

$$e_t = y_t - \hat{y}_t$$

Jika model mampu merepresentasikan dinamika utama sistem, maka residual diharapkan membentuk proses acak dengan nilai harapan nol dan tidak memiliki struktur dependensi temporal. Secara matematis, kondisi ideal residual dapat dinyatakan sebagai:

$$E[e_t] = 0$$

$$\text{Cov}(e_t, e_{t-k}) = 0 \quad \text{untuk setiap } k \neq 0$$

Kondisi ini menunjukkan bahwa seluruh informasi yang dapat diprediksi dari data historis telah diekstraksi oleh model, sedangkan komponen yang tersisa merupakan gangguan acak yang tidak dapat diprediksi.

Untuk menilai keberadaan autokorelasi residual orde pertama digunakan statistik Durbin-Watson. Statistik ini mengukur perubahan berturut-turut dalam residual relatif terhadap besarnya variasi residual secara keseluruhan. Secara matematis, statistik tersebut dinyatakan sebagai:

$$DW = \frac{\sum_{t=2}^N (e_t - e_{t-1})^2}{\sum_{t=1}^N e_t^2}$$

Nilai statistik ini berkaitan langsung dengan koefisien autokorelasi residual orde pertama ρ_1 melalui pendekatan:

$$DW \approx 2(1 - \rho_1)$$

Nilai DW mendekati dua menunjukkan bahwa ρ_1 mendekati nol, yang berarti tidak terdapat autokorelasi linear pada residual. Sebaliknya, nilai yang jauh lebih kecil dari dua menunjukkan autokorelasi positif yang kuat, sedangkan nilai yang jauh lebih besar dari dua menunjukkan autokorelasi negatif.

Hasil empiris menunjukkan perbedaan karakteristik residual yang sangat kontras antara model statis dan model dinamis. Model regresi polinomial menghasilkan nilai statistik Durbin-Watson yang sangat kecil, yaitu 0.0067. Nilai ini menunjukkan bahwa perubahan residual antar waktu sangat kecil dibandingkan variasi residual secara keseluruhan, yang berarti residual memiliki autokorelasi positif yang sangat kuat. Secara statistik, kondisi ini menunjukkan bahwa kesalahan prediksi pada suatu waktu memiliki keterkaitan kuat dengan kesalahan pada waktu sebelumnya. Dengan kata lain, model tidak berhasil menangkap struktur dinamika temporal yang mendasari runtun waktu log return. Keberadaan autokorelasi residual yang kuat merupakan

indikasi bahwa informasi prediktif masih tersisa dalam data, sehingga model belum memanfaatkan seluruh informasi historis yang tersedia.

Sebaliknya, model CMAC dengan lag eksplisit dan model ANN Time-Delay menghasilkan nilai statistik Durbin–Watson yang mendekati dua, masing-masing sebesar 2.4654 dan 2.4838. Nilai ini menunjukkan bahwa residual prediksi tidak memiliki autokorelasi positif yang signifikan dan mendekati karakteristik proses acak. Dalam kerangka pemodelan runtun waktu, kondisi ini menunjukkan bahwa struktur dependensi linear orde pertama pada data telah direpresentasikan secara memadai oleh model. Dengan demikian, kesalahan prediksi yang tersisa dapat diinterpretasikan sebagai komponen acak yang tidak dapat diprediksi secara sistematis.

Ketiadaan autokorelasi residual pada model dinamis memiliki implikasi metodologis yang penting. Dalam teori pemodelan stokastik, model dikatakan memadai jika residualnya bersifat white noise, yaitu proses acak dengan varian konstan dan tanpa korelasi temporal. Secara formal, proses white noise memenuhi:

$$e_t \sim WN(0, \sigma^2)$$

dengan σ^2 adalah varians konstan. Meskipun pengujian white noise secara lengkap memerlukan analisis autokorelasi pada berbagai lag, nilai Durbin–Watson yang mendekati dua memberikan indikasi awal bahwa residual telah kehilangan struktur temporal utama.

Perbedaan karakteristik residual antara model statis dan dinamis juga memperkuat interpretasi mengenai peran struktur memori temporal dalam pemodelan runtun waktu finansial. Model yang tidak memasukkan informasi lag menghasilkan residual yang terstruktur, sedangkan model yang menggunakan representasi keadaan berbasis lag menghasilkan residual yang mendekati proses acak. Hal ini menunjukkan bahwa dependensi temporal jangka pendek merupakan komponen utama yang dapat dipelajari dari data.

Analisis residual juga memberikan perspektif terhadap keterbatasan prediktibilitas log return. Meskipun model dinamis berhasil menghilangkan autokorelasi residual, nilai koefisien determinasi tetap mendekati nol. Kondisi ini menunjukkan bahwa komponen acak pada perubahan harga saham masih dominan dibandingkan komponen deterministik yang dapat dipelajari. Dengan demikian, hasil prediksi yang diperoleh mencerminkan batas empiris kemampuan model dalam mengekstraksi informasi prediktif dari data historis.

Secara keseluruhan, analisis residual menunjukkan bahwa model dengan lag eksplisit telah memenuhi kriteria dasar validitas statistik dalam pemodelan runtun waktu, yaitu residual yang tidak berkorelasi secara temporal. Sebaliknya, model tanpa representasi dinamika waktu menghasilkan residual yang sangat terstruktur dan tidak memenuhi asumsi independensi. Temuan ini memperkuat kesimpulan bahwa keberadaan memori temporal eksplisit merupakan prasyarat utama bagi validitas model prediksi runtun waktu finansial.

3.4 Implikasi untuk Pemodelan Time Series Finansial

Hasil empiris penelitian ini memberikan implikasi metodologis yang penting bagi pemodelan runtun waktu finansial, khususnya dalam konteks prediksi perubahan harga saham berbasis data historis. Temuan utama menunjukkan bahwa keberhasilan model tidak terutama

ditentukan oleh kompleksitas fungsi aproksimasi, melainkan oleh kesesuaian struktur model dengan sifat stokastik dan dinamis dari sistem finansial.

Runtun waktu harga saham secara umum dapat direpresentasikan sebagai proses stokastik yang terdiri atas komponen deterministik terbatas dan komponen acak dominan. Jika P_t menyatakan harga saham pada waktu ke- t , maka dinamika perubahan harga dapat dinyatakan sebagai:

$$P_t = P_{t-1} \exp(r_t)$$

dengan r_t adalah log return yang merepresentasikan perubahan relatif harga. Dalam kerangka stokastik, log return sering dimodelkan sebagai:

$$r_t = \mu_t + \varepsilon_t$$

dengan μ_t adalah komponen sistematis yang berpotensi diprediksi dari informasi historis, dan ε_t adalah komponen acak yang tidak dapat diprediksi secara deterministik.

Hasil penelitian menunjukkan bahwa komponen sistematis μ_t bersifat lemah dan bergantung pada informasi historis jangka pendek. Kondisi ini tercermin dari keberhasilan model yang memasukkan struktur lag eksplisit dalam menghasilkan residual yang tidak berkorelasi. Secara konseptual, dinamika runtun waktu finansial lebih tepat direpresentasikan sebagai sistem dengan memori terbatas:

$$r_t = f(r_{t-1}, r_{t-2}, \dots, r_{t-p}) + \varepsilon_t$$

dengan $f(\cdot)$ adalah fungsi nonlinier yang merepresentasikan struktur prediktif terbatas dalam data. Representasi ini menunjukkan bahwa informasi relevan untuk prediksi terkonsentrasi pada sejumlah kecil observasi historis yang berdekatan secara temporal.

Kegagalan model statis berbasis aproksimasi global memberikan implikasi penting mengenai ketidakesesuaian pendekatan deterministik global untuk sistem finansial. Model yang mengasumsikan hubungan tetap antara variabel tanpa mempertimbangkan dinamika temporal tidak mampu menangkap struktur informasi yang berubah terhadap waktu. Secara matematis, model statis mengasumsikan hubungan:

$$r_t = g(x_t) + \varepsilon_t$$

dengan x_t adalah variabel penjelas tanpa representasi keadaan sistem. Struktur semacam ini tidak memadai untuk sistem dinamis yang evolusinya bergantung pada keadaan historis.

Keberhasilan model dengan lag eksplisit menunjukkan bahwa pemodelan finansial harus dipahami sebagai masalah estimasi fungsi transisi keadaan. Dalam perspektif sistem dinamis, runtun waktu finansial dapat dipandang sebagai sistem evolusi keadaan diskret:

$$s_t = \Phi(s_{t-1}) + \eta_t$$

dengan vektor keadaan:

$$s_t = \begin{bmatrix} r_t \\ r_{t-1} \\ \vdots \\ r_{t-p+1} \end{bmatrix}$$

Model prediksi pada dasarnya berupaya mengaproksimasi operator transisi $\Phi(\cdot)$. Dengan demikian, keberhasilan pemodelan lebih bergantung pada kemampuan merepresentasikan keadaan sistem daripada pada kompleksitas bentuk fungsi aproksimasi.

Kesetaraan performa antara model CMAC dan ANN Time-Delay memberikan implikasi tambahan mengenai batas empiris prediktabilitas pada data finansial. Kedua model memiliki kapasitas aproksimasi nonlinier yang tinggi, namun menghasilkan tingkat kesalahan prediksi yang hampir identik. Hal ini menunjukkan bahwa struktur prediktif dalam log return memiliki dimensi informasi yang terbatas. Secara statistik, kondisi ini konsisten dengan asumsi bahwa komponen acak ε_t memiliki varians yang relatif besar dibandingkan komponen sistematis:

$$\text{Var}(\varepsilon_t) \gg \text{Var}(\mu_t)$$

Implikasi dari kondisi tersebut adalah bahwa peningkatan kompleksitas model tidak selalu menghasilkan peningkatan performa prediksi yang signifikan. Dalam sistem dengan struktur prediktif lemah, model yang stabil dan mampu merepresentasikan dinamika dasar seringkali memiliki kinerja yang setara dengan model yang jauh lebih kompleks.

Hasil penelitian juga memberikan implikasi terhadap validitas pendekatan prediksi berbasis data historis dalam konteks pasar finansial. Residual model dinamis yang mendekati proses acak menunjukkan bahwa setelah struktur temporal jangka pendek dimodelkan, sisa variasi harga tidak mengandung pola sistematis yang kuat. Secara matematis, kondisi ini dapat dinyatakan sebagai:

$$E[r_t | \mathcal{F}_{t-1}] \approx f(r_{t-1}, \dots, r_{t-p})$$

dengan \mathcal{F}_{t-1} adalah himpunan informasi historis hingga waktu $t - 1$. Setelah fungsi prediktif $f(\cdot)$ diestimasi, komponen residual mendekati proses acak yang tidak dapat diprediksi lebih lanjut.

Temuan ini menunjukkan bahwa pemodelan runtun waktu finansial sebaiknya difokuskan pada representasi dinamika jangka pendek yang stabil dan robust terhadap noise, bukan pada pencarian struktur deterministik kompleks yang bersifat global. Dalam kerangka metodologis, pemodelan berbasis keadaan dengan memori terbatas merupakan pendekatan yang lebih sesuai dibandingkan aproksimasi statis global.

Secara keseluruhan, implikasi utama penelitian ini adalah bahwa pemodelan runtun waktu finansial memerlukan integrasi antara representasi memori temporal dan aproksimasi nonlinier yang stabil. Model yang mengakomodasi dinamika sistem melalui struktur lag eksplisit mampu menangkap komponen prediktif terbatas yang tersedia dalam data, sedangkan model tanpa

representasi temporal gagal memenuhi kriteria validitas statistik. Temuan ini menegaskan bahwa struktur dinamis merupakan karakteristik fundamental yang harus dipertimbangkan dalam pengembangan model prediksi perubahan harga saham berbasis data historis.

4. KESIMPULAN

Penelitian ini bertujuan membandingkan kemampuan model statis dan model dinamis dalam memprediksi runtun waktu finansial berbasis log return harga saham harian. Evaluasi dilakukan menggunakan skema train–test berbasis waktu untuk menilai kemampuan generalisasi model pada data out-of-sample. Hasil empiris menunjukkan perbedaan performa yang sangat jelas antara pendekatan pemodelan yang tidak mengakomodasi struktur temporal dan pendekatan yang memasukkan memori historis secara eksplisit.

Model regresi polinomial orde tinggi menunjukkan kegagalan generalisasi yang signifikan pada data pengujian. Nilai kesalahan prediksi yang sangat besar serta residual yang memiliki autokorelasi kuat menunjukkan bahwa model statis berbasis aproksimasi global tidak mampu merepresentasikan dinamika runtun waktu finansial. Temuan ini menegaskan bahwa hubungan deterministik global tidak memadai untuk menggambarkan evolusi perubahan harga saham yang bersifat stokastik dan bergantung pada keadaan historis.

Sebaliknya, model CMAC dengan lag eksplisit dan model Artificial Neural Network Time-Delay menghasilkan performa prediksi yang jauh lebih baik dan memiliki karakteristik residual yang mendekati proses acak. Kedua model tersebut berhasil menangkap struktur dependensi temporal jangka pendek yang terdapat dalam data log return. Kesetaraan performa antara CMAC dan ANN menunjukkan bahwa keberhasilan pemodelan lebih ditentukan oleh keberadaan representasi memori temporal daripada oleh kompleksitas aproksimasi nonlinier global.

Implikasi metodologis utama dari penelitian ini adalah bahwa pemodelan runtun waktu finansial sebaiknya diposisikan sebagai masalah estimasi sistem dinamis dengan memori terbatas. Struktur lag eksplisit berfungsi sebagai representasi keadaan sistem yang memungkinkan model mengekstraksi informasi prediktif dari data historis. Hasil penelitian juga menunjukkan bahwa komponen deterministik dalam perubahan harga saham relatif kecil dibandingkan komponen acak, sehingga peningkatan kompleksitas model tidak selalu menghasilkan peningkatan akurasi prediksi yang signifikan.

Penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan. Pertama, jumlah observasi relatif terbatas sehingga estimasi model dilakukan pada horizon waktu yang pendek. Kedua, model hanya menggunakan informasi historis harga tanpa memasukkan variabel eksternal seperti indikator teknikal atau faktor fundamental. Ketiga, evaluasi performa dilakukan pada satu instrumen saham sehingga generalisasi terhadap instrumen lain memerlukan pengujian tambahan.

Penelitian selanjutnya dapat diarahkan pada pengembangan model dengan representasi keadaan yang lebih kaya, termasuk integrasi variabel eksogen dan pendekatan multivariat. Penggunaan skema evaluasi rolling forecasting juga dapat memberikan gambaran yang lebih komprehensif mengenai stabilitas model terhadap perubahan struktur pasar. Selain itu, eksplorasi metode pembelajaran adaptif yang mampu menyesuaikan parameter model secara dinamis terhadap perubahan distribusi data merupakan arah penelitian yang menjanjikan dalam pemodelan runtun waktu finansial.

Secara keseluruhan, penelitian ini menunjukkan bahwa representasi dinamika temporal merupakan komponen esensial dalam pemodelan prediksi perubahan harga saham. Model yang mengintegrasikan memori historis secara eksplisit terbukti lebih sesuai untuk merepresentasikan karakteristik runtun waktu finansial dibandingkan model statis berbasis aproksimasi global. Temuan ini memberikan kontribusi metodologis bagi pengembangan pendekatan pemodelan yang lebih realistis dan konsisten dengan sifat stokastik sistem finansial.

DAFTAR PUSTAKA

- Bennett S., Mihai Cucuringu, Gesine Reinert (2021). Detection and clustering of lead-lag networks for multivariate time series with an application to financial markets. https://kdd-milets.github.io/milets2021/papers/MiLeTS2021_paper_10.pdf
- Chatterjee A., Hrisav Bhowmick, Jaydip Sen (2021). Stock Price Prediction Using Time Series, Econometric, Machine Learning, and Deep Learning Models. <https://arxiv.org/abs/2111.01137>
- Enow S.T. (2023). Random walk and modelling stock return: Evidence from international stock markets. *International Journal of Research in Business and Social Science* (2147- 4478), 12(3), 353-360. <https://doi.org/10.20525/ijrbs.v12i3.2443>
- Lawal A.A., Omogbolahan Alli, Aishat Oluwatoyin Olatunji, Enuma Ezeife, and Ehizele Dean Okoduwa (2023). Time series analysis and forecasting in finance: A data mining approach. *Open Access Research Journal of Science and Technology*, 09(01), 075-086. <https://doi.org/10.53022/oarjst.2023.9.1.0045>
- Lu, C.J., Wu, J.Y. (2010). Forecasting Financial Time Series via an Efficient CMAC Neural Network. In: Zeng, Z., Wang, J. (eds) *Advances in Neural Network Research and Applications*. Lecture Notes in Electrical Engineering, vol 67. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-12990-2_9
- Masini R. P., Marcelo C. Medeiros, Eduardo F. Mendes (2023). Machine learning advances for time series forecasting. *Journal of Economic Surveys*. Volume37, Issue1, Pages 76-111. <https://doi.org/10.1111/joes.12429>
- McMillan, D.G. (2021). Forecasting sector stock market returns. *J Asset Manag* 22, 291–300. <https://doi.org/10.1057/s41260-021-00220-6>
- Mo H., (2023). Comparative Analysis of Linear Regression, Polynomial Regression, and ARIMA Model for Short-term Stock Price Forecasting. *Proceedings of the 2nd International Conference on Financial Technology and Business Analysis*. DOI: 10.54254/2754-1169/49/20230509
- Mücher C (2022) Artificial Neural Network Based Non-linear Transformation of High-Frequency Returns for Volatility Forecasting. *Front. Artif. Intell.* 4:787534. doi: 10.3389/frai.2021.787534
- Nguyen, V.-T., Pham, D.-H., Mai, V. T., Nguyen, H.-N., & Phan, M.-T. (2025). Design of Intelligent Control Using Dynamic Petri, CMAC, and BCMO for Nonlinear Systems with Uncertainties. *Mathematics*, 13(17), 2825. <https://doi.org/10.3390/math13172825>

- Sako, K., Mpinda, B. N., & Rodrigues, P. C. (2022). Neural Networks for Financial Time Series Forecasting. *Entropy*, 24(5), 657. <https://doi.org/10.3390/e24050657>
- Staněk F. (2023). Optimal out-of-sample forecast evaluation under stationarity. *Journal of Forecasting*, Volume 42, Issue 8, Pages 2249-2279. <https://doi.org/10.1002/for.3013>
- Tang Q., Tongmei Fan, Ruchen Shi, Jingyan Huang, Yidan Ma (2021). Prediction of financial time series using LSTM and data denoising methods. <https://arxiv.org/abs/2103.03505>
- Xu, F., Xu, J., Zhang, J., Zhang, C., & Wang, Z. (2021). Research on parallel control of CMAC and PD based on U model. *Automatika*, 62(3–4), 331–338. <https://doi.org/10.1080/00051144.2021.1954782>
- Zhang C., Yihuang Zhang, Mihai Cucuringu, Zhongmin Qian (2024). Volatility Forecasting with Machine Learning and Intraday Commonality. *Journal of Financial Econometrics*, Vol. 22, No. 2, 492–530. <https://doi.org/10.1093/jjfinec/nbad005>
- Zikova A & Vesela J, (2021). WEAK FORM MARKET EFFICIENCY HYPOTHESIS TESTING – AUTOCORRELATION ANALYSIS AND UNIT ROOT TEST. Conference: IFRS: GLOBAL RULES & LOCAL USE-BEYOND THE NUMBERS. https://www.researchgate.net/publication/357517158_WEAK_FORM_MARKET_EFFICIENCY_HYPOTHESIS_TESTING_-_AUTOCORRELATION_ANALYSIS_AND_UNIT_ROOT_TEST