

BAB II KAJIAN LITERATUR

2.1 Analisis Data Eksploratif

Analisis Data Eksploratif atau *Exploratory Data Analysis* (EDA) merupakan sebuah pendekatan sistematis untuk menjelajahi data melalui penggunaan visualisasi, ringkasan statistik, serta identifikasi pola-pola yang mendasari himpunan data (*dataset*). Sebagai langkah awal yang umum dalam setiap alur kerja analitik data, EDA memungkinkan analisis untuk mendeteksi dependensi serta hubungan antar faktor guna memvalidasi asumsi awal dan mengurangi potensi kegagalan pada analisis tingkat lanjut. Pendekatan ini membantu mengungkap wawasan penting seperti pencilan (*outliers*), hubungan internal dalam *dataset*, dan tren yang ada, sehingga memberikan fondasi yang kuat untuk pengembangan alur kerja dan penerapan model pembelajaran mesin. Berbeda dengan *Confirmatory Data Analysis* (CDA) yang bertujuan untuk mengonfirmasi atau menyangkal argumen tertentu, EDA dilakukan tanpa adanya prasangka atau asumsi awal (*preconceptions*) agar pola dan tren dapat muncul secara organik dari data tersebut [17].

Dalam konteks data deret waktu (*time series*), tahapan analisis EDA meliputi analisis deskriptif untuk merangkum poin-poin data serta pembuatan plot untuk mengamati tren dan pola musiman secara visual. Salah satu aspek teoretis yang krusial dalam eksplorasi deret waktu adalah pemeriksaan stasioneritas, di mana data dianggap stasioner apabila nilainya berfluktuasi di sekitar rata-rata yang konstan dan memiliki varians yang relatif stabil sepanjang periode pengamatan. Selain itu, EDA juga berfungsi untuk mendeteksi keberadaan data yang hilang (*missing value*) yang dapat menyebabkan ketidakaturan interval waktu. Kondisi interval waktu yang tidak konsisten dianggap melanggar syarat dasar data deret waktu, sehingga melalui proses eksplorasi ini dapat ditentukan metode penanganan yang tepat, seperti penggunaan interpolasi linear, sebelum dilakukan pemodelan lebih lanjut [18].

2.1.1 Statistik Deskriptif

Statistik deskriptif merupakan bidang statistika yang berfokus pada metode pengumpulan, pengolahan, penyajian, hingga penganalisisan data kuantitatif untuk memberikan gambaran komprehensif mengenai karakteristik suatu kelompok data tanpa tujuan penarikan kesimpulan yang lebih luas [19]. Pendekatan ini bertujuan utama meringkas fitur-fitur penting dari kumpulan data agar informasi yang terkandung di

dalamnya menjadi lebih mudah dipahami melalui penggunaan ukuran pemusatan, ukuran penyebaran, serta ukuran bentuk distribusi data [19][20]. Dalam praktiknya, statistik deskriptif menjadi fondasi utama bagi peneliti untuk memahami struktur data mentah sebelum melangkah ke tahap pengujian hipotesis atau pemodelan prediktif yang lebih kompleks [19].

Dalam upaya menentukan titik pusat distribusi, digunakan ukuran pemusatan data (*measures of central tendency*) yang meliputi tiga indikator utama, yaitu *mean*, *median*, dan modus. Indikator *mean* atau rata-rata diperoleh melalui pembagian jumlah seluruh nilai data dengan banyaknya data guna memberikan gambaran nilai tipikal pada distribusi tersebut. Sementara itu, *median* berperan sebagai nilai tengah yang membagi data menjadi dua bagian sama besar setelah diurutkan, yang memiliki keunggulan berupa sifat yang lebih stabil terhadap keberadaan pencilan dibandingkan *mean*. Sebagai pelengkap, modus digunakan untuk merepresentasikan nilai dengan frekuensi kemunculan paling tinggi, sehingga peneliti dapat mengidentifikasi kecenderungan dominan yang muncul dalam kumpulan data yang diamati [20].

Selain berfokus pada titik pusat, statistik deskriptif juga menggunakan ukuran penyebaran data (*measures of dispersion*) untuk menggambarkan tingkat keragaman atau variasi dalam *dataset*. Salah satu indikator fundamentalnya adalah standar deviasi yang menyajikan informasi mengenai rata-rata jarak penyimpangan setiap titik data dari nilai rata-ratanya, sehingga secara teoretis mencerminkan tingkat volatilitas data yang sedang dianalisis [19]. Pengukuran variansi ini sangat krusial dalam analisis data finansial guna melihat seberapa jauh data berfluktuasi dari nilai pusatnya dalam periode waktu tertentu. Dengan memahami persebaran data, peneliti dapat menilai kualitas dan konsistensi dari sampel data yang digunakan dalam penelitian [19].

Lebih lanjut, profil distribusi data dapat dipahami secara mendalam melalui ukuran bentuk distribusi (*measures of shape*) yang mencakup *skewness* dan *kurtosis*. *Skewness* atau kemiringan merupakan ukuran statistik untuk menentukan derajat ketidaksimetrisan distribusi data, di mana sebuah distribusi dikatakan normal apabila memiliki nilai *skewness* sama dengan nol. Di sisi lain, *kurtosis* atau keruncingan digunakan untuk menunjukkan derajat ketinggian puncak distribusi data jika dibandingkan dengan distribusi normal. Analisis terhadap *kurtosis* menjadi sangat krusial, terutama untuk mengidentifikasi apakah sebuah *dataset* memiliki karakteristik ekor yang berat (*heavy tails*) atau nilai ekstrem, yang umumnya ditemukan dalam data finansial yang tidak berdistribusi normal secara sempurna [21].

2.1.2 Visualisasi Runtun Waktu

Visualisasi runtun waktu atau *time series visualization* merupakan tahapan kritis dalam analisis data untuk mengidentifikasi komponen-komponen utama yang terkandung dalam deret data, seperti tren, pola musiman (*seasonality*), siklus, dan variasi residu yang tidak teratur. Secara teoretis, visualisasi ini dilakukan dengan memetakan titik-titik data berdasarkan urutan kronologis waktu guna mengekstraksi informasi bermakna dari data mentah melalui serangkaian siklus yang terstruktur. Melalui representasi grafis, peneliti dapat melakukan transformasi data untuk menemukan pola tersembunyi dalam *dataset* yang kompleks, yang sekaligus berfungsi sebagai alat validasi terhadap kondisi aktual dari variabel yang diamati [22].

Dalam analisis deret waktu finansial, grafik visual digunakan secara spesifik untuk membedakan empat komponen primer yang mempengaruhi pergerakan data. Komponen pertama adalah tren yang menunjukkan kecenderungan pergerakan jangka panjang, baik itu pola yang meningkat maupun menurun seiring berjalannya waktu. Komponen kedua adalah pola musiman (*seasonal*), yaitu fluktuasi yang berulang secara periodik dalam rentang waktu tertentu yang sering kali dipengaruhi oleh siklus kalender atau faktor eksternal lainnya [22].

Selain tren dan pola musiman, visualisasi juga bertujuan untuk mengidentifikasi komponen siklis (*cyclical*) dan *irregular* (tidak teratur). Komponen siklis mencerminkan fluktuasi ekonomi yang muncul dalam jangka waktu yang lebih panjang dengan periode yang tidak tetap, sehingga sulit diprediksi tanpa pengamatan visual yang mendalam. Sementara itu, komponen *irregular* atau residu merepresentasikan gejolak tak terduga, volatilitas, atau gangguan yang bersifat acak dan tidak memiliki pola tertentu. Pemetaan sistematis terhadap keempat komponen ini memastikan bahwa setiap informasi temporal yang penting tetap terjaga, sehingga model prediktif yang dibangun dapat mencerminkan perilaku data secara objektif sesuai dengan karakteristik aslinya [22].

2.1.3 Analisis Korelasi dan Hubungan Antarvariabel

Analisis korelasi merupakan salah satu teknik statistik yang paling banyak digunakan untuk mengetahui derajat hubungan linear antara dua variabel atau lebih dalam sebuah penelitian kuantitatif. Secara teoretis, analisis ini bertujuan untuk mengukur sejauh mana perubahan pada variabel independen diikuti oleh perubahan pada variabel dependen, baik dalam arah yang sama maupun berlawanan. Penentuan jenis uji korelasi yang digunakan sangat bergantung pada skala data dan pemenuhan asumsi statistik, seperti normalitas dan

linearitas, guna memastikan bahwa variabel eksternal yang digunakan memang memiliki pengaruh secara statistik terhadap target prediksi [23].

Dalam konteks analisis multivariat, penjelasan mengenai hubungan antarvariabel menjadi lebih kompleks karena melibatkan pengamatan terhadap lebih dari dua variabel secara simultan untuk memahami struktur keterkaitan yang mendasarinya [24]. Pengujian dalam kerangka multivariat ini sangat krusial untuk mengukur kekuatan hubungan melalui koefisien korelasi guna menjamin bahwa variabel-variabel independen yang dipilih memiliki kontribusi signifikan terhadap variabel target [23][24]. Selain itu, pemahaman mendalam mengenai korelasi dalam sistem multivariat berfungsi untuk mendeteksi adanya multikolinearitas yang dapat mengganggu stabilitas serta akurasi model prediktif yang akan dibangun [24].

Lebih lanjut, koefisien korelasi yang dihasilkan memberikan indikasi mengenai arah hubungan, di mana nilai positif menunjukkan hubungan searah dan nilai negatif menunjukkan hubungan terbalik antara variabel-variabel yang diamati [23]. Selain mengukur keeratan hubungan secara matematis, analisis korelasi juga berfungsi sebagai kajian konseptual untuk menelaah keunggulan dan keterbatasan model dalam konteks penggunaan praktis pada berbagai bidang penelitian [23]. Dengan memastikan validitas analisis korelasi melalui pengujian asumsi statistik yang ketat, peneliti dapat menjamin bahwa hasil pemetaan hubungan antarvariabel mencerminkan pola data yang objektif dan dapat dipertanggungjawabkan secara ilmiah [23][24].

2.2 Prapemrosesan Data


Prapemrosesan data atau *data preprocessing* merupakan tahapan fundamental untuk mentransformasi data mentah menjadi representasi yang dapat dipelajari secara optimal oleh jaringan saraf tiruan. Mengingat data finansial multivariat memiliki karakteristik yang volatil serta non-stasioner, diperlukan teknik standarisasi dan rekayasa fitur yang ketat guna meningkatkan akurasi prediksi [25]. Selain itu, karena data berasal dari berbagai pasar dengan kalender operasional yang berbeda, pengolahan awal menjadi kunci untuk menyelaraskan variabel agar model dapat menangkap dependensi temporal secara efektif [26]. Melalui tahapan ini, deret waktu yang kompleks disederhanakan tanpa menghilangkan informasi esensial, sehingga mempermudah algoritma dalam mengenali pola-pola tren di masa depan.

Efektivitas prapemrosesan juga sangat menentukan ketahanan model dalam menghadapi fluktuasi pasar yang ekstrem. Pembersihan data yang dilakukan secara

sistematis memungkinkan model untuk membedakan antara sinyal tren yang berarti dengan derau yang sering muncul pada data nilai tukar [27]. Dengan memastikan bahwa *dataset* telah melalui tahap normalisasi dan pembersihan yang konsisten, arsitektur *deep learning* dapat mencapai stabilitas numerik yang lebih baik selama proses pembaruan bobot. Hal ini pada akhirnya meminimalkan risiko kesalahan prediksi dan memperkuat validitas hasil peramalan pada kondisi ekonomi yang dinamis [25] [27]

2.2.1 Penanganan Data Hilang dan Imputasi

Data finansial sering kali memiliki kekosongan nilai pada hari libur bursa atau periode non-perdagangan lainnya. Penggunaan metode *Forward Fill (ffill)* menjadi sangat krusial dalam deret waktu finansial karena teknik ini mempertahankan informasi harga terakhir yang tersedia sebagai estimasi kondisi pasar pada saat kekosongan terjadi [28]. Langkah ini memastikan bahwa kontinuitas temporal tetap terjaga sehingga model LSTM dapat mempelajari urutan waktu secara utuh tanpa terputus oleh nilai *null*. Jika dibiarkan, kekosongan data tersebut dapat merusak pemodelan pola sekuensial dan mengurangi kemampuan algoritma dalam menangkap dinamika pasar yang kompleks [29].



Gambar 2.1 Ilustrasi identifikasi celah data pada *dataset* multivariat dan mekanisme pengisian nilai menggunakan metode *Forward Fill* [30]


Implementasi strategi imputasi ini bertujuan untuk meminimalkan bias yang mungkin muncul akibat hilangnya informasi pada variabel dependen maupun independen. Dengan mengisi celah data menggunakan nilai historis terdekat, struktur *dataset* multivariat menjadi lebih stabil dan siap untuk diproses oleh arsitektur jaringan saraf tiruan [28]. Selain itu, pembersihan data dari nilai yang hilang secara sistematis merupakan prasyarat utama untuk menjamin efektivitas model *ensemble* atau *hybrid* dalam menghasilkan prediksi yang akurat selama periode volatilitas tinggi [29]. Hal ini memungkinkan model untuk mempertahankan memori jangka panjang terhadap tren harga tanpa terdistorsi oleh diskontinuitas data mentah.

2.2.2 Min-Max Scaling

Model *deep learning* sangat sensitif terhadap perbedaan skala pada data input. Tanpa melalui proses normalisasi, variabel dengan nominal angka yang besar, seperti Indeks Harga Saham Gabungan (IHSG), akan mendominasi variabel dengan angka yang relatif kecil, seperti harga minyak mentah WTI, dalam tahap pembaruan bobot (*gradient update*). Penggunaan *Min-Max Scaling* berfungsi mentransformasi seluruh fitur ke dalam rentang [0, 1], yang secara signifikan mempercepat proses konvergensi model serta memastikan stabilitas numerik selama fase pelatihan berlangsung [26]. Secara matematis, proses transformasi *Min-Max Scaling* dilakukan dengan menggunakan persamaan berikut [31]:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \dots \dots \dots (2.1)$$

Dimana x^i Adalah nilai hasil normalisasi, x adalah nilai asli, sedangkan x_{min} dan x_{max} merupakan nilai minimum dan maksimum dari fitur tersebut. Penerapan teknik ini secara teoretis mampu meminimalkan bias pada fitur dengan rentang nilai yang besar sehingga mempercepat proses pembaruan bobot menuju titik konvergensi yang optimal [26]. Selain itu, transformasi ini memastikan arsitektur jaringan saraf tetap stabil secara komputasi saat memproses data finansial yang memiliki tingkat volatilitas tinggi [32].



Gambar 2.2 Distribusi rata-rata skor R2 pada berbagai model regresi yang menunjukkan stabilitas dan konsistensi performa hasil akurasi saat menggunakan metode *Min-Max Scaling* [33]

Selain meningkatkan efisiensi komputasi, teknik normalisasi ini juga berperan penting dalam menjaga integritas hubungan antar variabel dalam *dataset* multivariat. Dengan menyamakan rentang nilai seluruh fitur, model dapat mengekstraksi informasi dari setiap variabel secara proporsional tanpa terdistorsi oleh perbedaan satuan ukur [32]. Mengingat *output* yang dihasilkan model masih berada dalam rentang [0, 1], maka


diperlukan proses denormalisasi untuk mengembalikan nilai prediksi tersebut ke dalam satuan aslinya melalui persamaan [31] :

$$x = x' \times (x_{max} - x_{min}) + x_{min} \dots\dots\dots(2.2)$$

Dimana x adalah nilai aktual, x^i adalah nilai hasil prediksi model, sedangkan x_{max} dan x_{min} merupakan nilai ekstrem pada data asli. Transformasi ini memastikan bahwa arsitektur jaringan saraf mampu mengenali pola volatilitas pada nilai tukar secara lebih objektif, sehingga menghasilkan prediksi yang lebih konsisten terhadap perubahan tren pasar yang dinamis [32] [26]. Implementasi denormalisasi ini memungkinkan hasil prediksi yang dihasilkan dalam skala relatif $\{0, 1\}$ dipetakan kembali ke dalam satuan moneter aslinya, sehingga memudahkan interpretasi terhadap nilai tukar riil dan memvalidasi presisi model dalam kondisi pasar yang berfluktuasi [32].

2.2.3 Transformasi Sliding Window

Agar data dapat diproses oleh arsitektur sekuensial, data diubah menjadi struktur tiga dimensi yang terdiri dari *samples*, *time steps*, dan *features*. Dengan menetapkan *window size* tertentu, seperti 30 hari pengamatan, model dipaksa untuk melihat konteks historis sebagai input untuk memprediksi satu titik nilai di masa depan. Secara teoretis, transformasi ini memungkinkan lapisan CNN untuk mengekstraksi fitur spasial lokal di dalam jendela waktu tersebut sebelum dianalisis lebih lanjut oleh lapisan LSTM [25] [34]. Praktik ini merupakan standar dalam peramalan modern guna memastikan bahwa model tidak hanya melihat data secara statis, melainkan sebagai satu kesatuan urutan yang saling berkaitan [34].



Gambar 2.3 Implementasi Teknik *Sliding Window* [35]

Implementasi teknik *sliding window* ini sangat krusial dalam pembentukan deret waktu yang akan dipelajari oleh model *hybrid*. Melalui pergeseran jendela waktu secara konsisten, *dataset* multivariat dapat dipecah menjadi pola-pola temporal yang lebih kecil

namun tetap mengandung informasi tren dan volatilitas yang utuh [32]. Proses ini memastikan bahwa setiap input yang masuk ke dalam jaringan saraf tiruan telah memiliki representasi urutan yang stabil, sehingga memudahkan model dalam menangkap ketergantungan jangka panjang (*long-term dependencies*) dari variabel nilai tukar dan indikator eksternal lainnya [32] [25].

2.3 Pembelajaran Mesin (*Machine Learning*)

Machine Learning (ML) merupakan domain dalam kecerdasan buatan yang memungkinkan sistem untuk mempelajari pola secara mandiri dari *dataset* historis guna menghasilkan prediksi yang objektif. Dalam analisis deret waktu finansial, keunggulan utama ML terletak pada kemampuannya dalam menangani data yang bersifat non-linier, volatil, dan memiliki dimensi yang kompleks. Pendekatan ini terbukti lebih efektif dibandingkan metode ekonometrika tradisional karena algoritma ML dapat mengidentifikasi keterkaitan antar variabel ekonomi yang rumit tanpa memerlukan asumsi distribusi data yang kaku [25]. Hal ini diperkuat oleh penelitian yang menunjukkan bahwa algoritma pembelajaran mesin memiliki kemampuan adaptif yang tinggi dalam menghadapi volatilitas ekstrem pada pergerakan nilai tukar rupiah terhadap dolar AS [4]. Dengan memanfaatkan berbagai indikator teknikal dan makroekonomi sebagai input, model pembelajaran mesin mampu mentransformasikan informasi masa lalu menjadi proyeksi masa depan yang lebih akurat dan responsif terhadap perubahan pasar [4] [26].


Evolusi *Machine Learning* menuju arsitektur yang lebih dalam (*Deep Learning*) telah memberikan lompatan signifikan dalam akurasi peramalan nilai tukar. Penggunaan jaringan saraf tiruan yang mendalam memungkinkan ekstraksi fitur dilakukan secara hierarkis, di mana model secara otomatis menyaring sinyal tren yang berarti dari derau pasar yang ekstrem [29]. Integrasi berbagai teknik ML ke dalam kerangka kerja yang sistematis memastikan bahwa setiap dinamika temporal dan interaksi antar variabel eksternal dapat dipetakan secara komprehensif [32]. Oleh karena itu, penerapan pembelajaran mesin dalam studi ini berfungsi sebagai instrumen analitis utama untuk mengatasi ketidakpastian pada pergerakan nilai tukar USD/IDR melalui pemodelan yang adaptif dan berbasis data [32] [29].

Selain kemampuan adaptifnya, keunggulan teknis dari pembelajaran mesin dalam arsitektur yang lebih mendalam terletak pada pemrosesan data multivariat secara simultan. Dalam sistem yang kompleks, variabel-variabel independen tidak hanya berdiri sendiri, melainkan memiliki keterkaitan urutan yang selaras secara waktu (*time-aligned sequences*). Penggunaan algoritma pembelajaran mesin yang dirancang untuk *Multivariate Time Series*

memungkinkan model untuk mengekstraksi ketergantungan antar variabel yang berbeda secara otomatis [36]. Hal ini memberikan kerangka kerja yang lebih tangguh dalam mengenali sinyal perdagangan dan tren ekonomi jangka panjang yang sering kali tertutup oleh volatilitas harian, sehingga memperkuat landasan teoretis bagi penggunaan model *hybrid* dalam memprediksi fluktuasi nilai tukar secara presisi [28] [36].

2.4 Peramalan Deret Waktu (Time Series Forecasting)

Peramalan atau *forecasting* didefinisikan sebagai disiplin ilmu yang mempelajari prediksi masa depan berdasarkan informasi masa lalu dan saat ini untuk meminimalkan ketidakpastian dalam pengambilan keputusan [34]. Dalam konteks ekonomi, peramalan bukan sekadar menebak angka, melainkan sebuah proses sistematis untuk mengidentifikasi pola struktural seperti tren, musiman, dan siklus yang terkandung dalam data historis [37]. Pentingnya peramalan nilai tukar menjadi sangat krusial bagi pemerintah maupun pelaku bisnis sebagai instrumen preventif guna mencegah dampak negatif depresiasi terhadap stabilitas ekonomi nasional [38] [39]. Penelitian terbaru menunjukkan bahwa integrasi antara indikator teknis tradisional dengan jaringan saraf tiruan dapat secara signifikan meningkatkan akurasi prediksi nilai tukar, terutama dalam menghadapi ketidakseimbangan struktural pada ekonomi negara berkembang [26].



Gambar 2.4 Visualisasi Peramalan Deret Waktu [22]

Secara teoretis, data deret waktu finansial memiliki tingkat kompleksitas yang tinggi karena sifatnya yang non-linear dan sering kali terkontaminasi oleh gangguan acak [10]. Literatur modern menekankan bahwa tantangan utama dalam peramalan saat ini adalah pemilihan metode yang tepat di antara spektrum luas yang tersedia, mulai dari metode

statistik tradisional yang bersifat parametrik hingga algoritma *Machine Learning* yang bersifat non-parametrik [34]. Meskipun metode konvensional seperti *Moving Average* unggul dalam aspek kesederhanaan, teknik tersebut sering kali gagal menangkap dinamika temporal yang kompleks pada data dengan volatilitas tinggi [27] [38]. Untuk mengatasi hal ini, penggunaan kerangka kerja pembelajaran multi-periode kini mulai dikembangkan guna menangkap karakteristik data finansial yang dipengaruhi oleh opini publik jangka pendek sekaligus tren pasar jangka panjang secara lebih efisien [28].

Perkembangan terkini menunjukkan adanya pergeseran signifikan ke arah penggunaan metode berbasis *Deep Learning* yang mampu mengekstraksi informasi dari data besar secara otomatis tanpa memerlukan asumsi statistik yang kaku [34]. Penggunaan model *hybrid*, seperti penggabungan CNN dan LSTM, kini menjadi standar baru untuk menangkap fitur spasial lokal sekaligus dependensi jangka panjang dalam satu arsitektur terpadu [10]. Selain itu, kombinasi model *hybrid* lain seperti LSTM-GRU yang mengintegrasikan variabel eksternal berupa sentimen berita terbukti mampu menangkap volatilitas aset finansial dengan lebih komprehensif dibandingkan model tunggal [32]. Keberhasilan suatu model peramalan pada akhirnya dievaluasi melalui metrik akurasi seperti *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) untuk memastikan kemampuan generalisasi yang baik terhadap data baru atau *out-of-sample* [38] [39].

2.5 Deep Learning

Deep Learning merupakan evolusi dari *Artificial Neural Networks* (ANN) yang terdiri dari banyak lapisan tersembunyi (*hidden layers*) untuk mengekstraksi representasi data secara hierarkis. Dalam analisis deret waktu finansial, *Deep Learning* telah membuktikan keunggulannya dibandingkan model statistik konvensional karena kemampuannya dalam menangani data yang bersifat non-linear, non-stasioner, dan memiliki kompleksitas tinggi [34]. Algoritma ini bekerja dengan cara mempelajari pola fitur secara otomatis dari data mentah, sehingga meminimalisir ketergantungan pada asumsi matematis yang kaku yang sering kali membatasi model klasik [27]. Efektivitas pendekatan ini sangat terlihat pada penggunaan algoritme *Long Short-Term Memory* (LSTM) yang mampu menangkap perilaku non-linear dan kompleks pada fluktuasi nilai tukar Rupiah terhadap USD secara lebih adaptif dibandingkan model linear [4].

Penerapan *Deep Learning* dalam prediksi nilai tukar menjadi sangat relevan terutama pada periode volatilitas tinggi dan ketidakpastian ekonomi global. Berdasarkan penelitian terbaru, model berbasis jaringan saraf memiliki performa yang lebih tangguh dalam

menghasilkan prediksi yang akurat selama periode guncangan pasar dibandingkan dengan model ekonomi moneter tradisional [27]. Hal ini dikarenakan *Deep Learning* mampu mengasimilasi berbagai variabel input multivariat secara bersamaan dan menemukan korelasi tersembunyi di antaranya [40]. Kemampuan untuk melakukan analisis multivariat yang mendalam ini sangat krusial dalam domain finansial, di mana representasi hierarkis dalam tiap lapisan model membantu mengidentifikasi ketergantungan antar-variabel yang selaras dalam sistem pasar yang kompleks [36].

Keunggulan utama dari pendekatan ini terletak pada fleksibilitas arsitekturnya. Penggunaan lapisan konvolusi memungkinkan model untuk menangkap fitur spasial lokal, sementara lapisan rekuren memungkinkan pemrosesan memori temporal jangka panjang. Integrasi antara *Convolutional Neural Networks* (CNN) untuk ekstraksi fitur dan LSTM untuk pemodelan sekuensial (model *hybrid* CNN-LSTM) terbukti memberikan hasil yang lebih superior dibandingkan model tunggal dalam mengenali pola rumit pada data pasar saham dan finansial [7]. Kemampuan untuk melakukan generalisasi terhadap data yang mengandung gangguan tinggi menjadikannya instrumen yang andal untuk menghasilkan peramalan nilai tukar yang lebih presisi, yang pada gilirannya dapat membantu dalam mitigasi risiko keuangan secara lebih efektif [27].

2.5.1 Dense Layer

Dense Layer atau yang secara teknis dikenal sebagai *Fully Connected Layer*, merupakan lapisan dalam arsitektur jaringan saraf tiruan di mana setiap *neuron* terhubung sepenuhnya dengan seluruh aktivasi dari lapisan sebelumnya. Lapisan ini berfungsi sebagai unit integrasi yang mengumpulkan fitur-fitur yang telah diekstraksi oleh lapisan terdahulu untuk kemudian dipetakan ke dalam ruang dimensi yang lebih rendah. Struktur ini memungkinkan jaringan untuk mempelajari kombinasi fitur yang kompleks secara global sebelum menghasilkan *output* akhir [41].

Implementasi lapisan ini biasanya melibatkan beberapa tingkatan *dense layer* dengan konfigurasi jumlah unit atau *node* tertentu guna memperdalam kapasitas pembelajaran model. Dengan adanya hubungan antar *neuron* yang menyeluruh, model dapat menangkap hubungan non-linier yang tersembunyi di dalam data melalui penyesuaian bobot selama proses pelatihan. *Output* dari lapisan *dense* terakhir umumnya akan diteruskan ke unit klasifikasi atau regresi untuk menentukan hasil akhir dari proses komputasi jaringan [41].

Secara matematis, proses transformasi data pada setiap *node* di dalam *dense layer* mengikuti prinsip fungsi affine primer yang melibatkan operasi linear antara input dan

parameter jaringan. Operasi ini melibatkan pembobotan vektor input dan penambahan bias untuk mengoptimalkan pemetaan data, yang dirumuskan sebagai berikut [41]:

$$y_j = w * h + b \dots \dots \dots (2.3)$$

Dimana y_j memerepresentasikan *output* dari lapisan *dense* untuk setiap unit j , sedangkan w merupakan vektor bobot (*weight vector*) yang berfungsi menyesuaikan kontribusi dari setiap fitur input yang diterima. Variabel h menyatakan vektor input atau representasi fitur yang berasal dari lapisan ekstraksi sebelumnya, dan b adalah bias yang berperan sebagai nilai intersep untuk mengoptimalkan pergeseran fungsi aktivasi guna meningkatkan akurasi model. Setelah nilai linier y_j diperoleh, model menerapkan fungsi aktivasi ReLU (*Rectified Linear Unit*) yang didefinisikan sebagai $\max\{0, y_j\}$ untuk memperkenalkan sifat non-linieritas ke dalam sistem [41].

2.5.2 Forward Propagation

Forward Propagation atau perambatan maju merupakan fase fundamental dalam operasional jaringan saraf tiruan, di mana data input diproses melalui urutan transformasi linier dan non-linier pada setiap lapisan secara searah. Mekanisme ini bekerja dengan mengalirkan informasi dari lapisan input menuju lapisan-lapisan tersembunyi (*hidden layers*) hingga mencapai lapisan *output* tanpa adanya siklus balik. Setiap lapisan dalam jaringan saraf melakukan komputasi aktif untuk mentransformasikan representasi data dari tingkat rendah menuju fitur tingkat tinggi yang lebih abstrak guna menghasilkan nilai estimasi akhir [42].

Selama proses perambatan maju berlangsung, setiap unit atau neuron pada suatu lapisan akan menerima sinyal aktivasi dari lapisan sebelumnya untuk kemudian dilakukan operasi matematika menggunakan parameter yang telah ditentukan. Informasi tersebut diproses secara sistematis sehingga setiap lapisan memberikan kontribusi dalam memetakan kompleksitas pola yang terdapat pada data masukan. Keberhasilan suatu arsitektur model dalam mengenali pola sangat bergantung pada efektivitas tahapan ini dalam mendistribusikan sinyal melalui fungsi aktivasi yang tepat guna mencapai target keluaran yang diinginkan [42].

Secara teknis, mekanisme perambatan maju melibatkan perhitungan nilai aktivasi pada setiap neuron yang melibatkan seluruh parameter bobot dan bias di dalam jaringan. Proses ini dilakukan secara berurutan mulai dari ekstraksi fitur awal hingga proses integrasi fitur pada lapisan terakhir sebelum hasil prediksi dikeluarkan. Melalui koordinasi alur data

yang teratur, *forward propagation* memungkinkan jaringan saraf tiruan untuk memetakan hubungan non-linier yang rumit antara variabel-variabel masukan dengan variabel keluaran yang menjadi target sasaran dalam suatu sistem pembelajaran mesin [42].

2.5.3 Backpropagation

Backpropagation merupakan algoritma pembelajaran utama pada jaringan saraf tiruan yang berfungsi untuk memperbarui parameter model berdasarkan nilai galat (*error*) yang dihasilkan pada fase *forward propagation*. Secara fundamental, proses ini bertujuan untuk meminimalkan fungsi kerugian (*loss function*) dengan menghitung gradien kerugian terhadap setiap bobot dan bias di dalam jaringan. Melalui mekanisme perambatan mundur, sinyal galat dialirkan dari lapisan output kembali ke lapisan-lapisan sebelumnya guna menentukan sejauh mana setiap parameter berkontribusi terhadap kesalahan prediksi yang terjadi [43].

Landasan matematis utama dalam penghitungan gradien pada proses ini adalah penggunaan aturan rantai atau *chain rule*. Aturan ini digunakan untuk menghitung turunan parsial dari fungsi kerugian terhadap parameter di setiap lapisan dengan cara mengalikan turunan turunan *loss* terhadap *output neuron* dengan turunan *output* terhadap bobot itu sendiri. Secara matematis, *chain rule* dirumuskan sebagai berikut [43]:

$$\frac{\partial L}{\partial w} = \frac{\partial L}{\partial y_j} \cdot \frac{\partial y_j}{\partial w} \dots \dots \dots (2.4)$$

Dimana $\frac{\partial L}{\partial w}$ merupakan gradien total dari fungsi kerugian terhadap bobot, yang menentukan arah dan besaran koreksi untuk parameter model, sedangkan $\frac{\partial L}{\partial y_j}$ merepresentasikan sinyal galat atau turunan parsial fungsi kerugian terhadap *output* neuron y_j , yang menunjukkan seberapa besar kesalahan yang dihasilkan oleh neuron tersebut, dan $\frac{\partial y_j}{\partial w}$ adalah turunan *output* terhadap bobot, yang dalam banyak arsitektur nilainya setara dengan nilai aktivasi atau input h dari lapisan sebelumnya. Operasi ini memungkinkan sistem untuk menentukan sensitivitas fungsi *loss* terhadap perubahan setiap bobot, sehingga dengan menerapkan prinsip ini secara berantai dari lapisan terakhir hingga lapisan awal, model dapat mengidentifikasi besarnya koreksi yang diperlukan pada setiap parameter guna meminimalkan galat secara bertahap [43].

Setelah nilai gradien diperoleh melalui *chain rule*, tahap selanjutnya adalah melakukan pembaruan parameter menggunakan algoritma optimasi seperti *Gradient*


Descent. Proses ini bertujuan untuk mengubah nilai bobot lama menjadi nilai baru yang lebih optimal dengan arah yang berlawanan dari gradien galat. Secara matematis, rumus pembaruan bobot tersebut didefinisikan sebagai berikut [42]:

$$W_{baru} = W_{lama} - \alpha \left(\frac{\partial L}{\partial w} \right) \dots \dots \dots (2.5)$$

Dimana W_{baru} merupakan nilai parameter setelah diperbarui, sedangkan W_{lama} adalah nilai parameter sebelum koreksi. Variabel α (*learning rate*) berfungsi sebagai pengatur besarnya langkah pembaruan, dan $\frac{\partial L}{\partial w}$ adalah gradien fungsi *loss* terhadap bobot yang telah dihitung sebelumnya. Melalui iterasi pembaruan parameter yang sistematis ini, jaringan saraf dapat secara bertahap meminimalkan galat dan meningkatkan akurasi model dalam mengenali pola data yang dipelajari [42].

2.6 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah jenis jaringan saraf tiruan yang memiliki kemampuan khusus dalam mengekstrak fitur dari data input melalui operasi konvolusi. Meskipun awalnya dirancang untuk data grid dua dimensi seperti citra, CNN telah diadaptasi secara luas untuk analisis data deret waktu (*time series*) keuangan menggunakan arsitektur *1D-CNN* [44].



Gambar 2.5 Arsitektur *CNN 1D* [45]

Proses ekstraksi fitur pada *1D-CNN* melibatkan operasi matematika antara input data dengan serangkaian filter (kernel) yang bergeser sepanjang sumbu waktu. Jika diberikan vektor input deret waktu x dengan panjang n , operasi konvolusi pada langkah waktu ke- t dengan filter w berukuran k dapat dinyatakan dalam persamaan berikut [46]:

$$z_t = f\left(\sum_{i=0}^{k-1} w_i \cdot x_{t+i} + b\right) \dots \dots \dots (2.6)$$


Dimana z_t adalah nilai fitur hasil konvolusi (*feature map*), w_i adalah bobot pada filter (kernel), $x_{(t+i)}$ adalah nilai input pada rentang waktu lokal. b adalah bias, f adalah fungsi

aktivasi non-linear, yang umumnya menggunakan *Rectified Linear Unit* (ReLU) untuk mempercepat konvergensi dan mengatasi masalah *vanishing gradient*. Dalam arsitektur model *hybrid*, *output* dari CNN yang telah tereduksi dan bersih kemudian akan menjadi input bagi lapisan selanjutnya, seperti LSTM, untuk dipelajari ketergantungan jangka panjangnya (*long-term dependencies*).

2.7 Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah arsitektur jaringan saraf tiruan yang merupakan pengembangan dari *Recurrent Neural Network* (RNN). Model ini dirancang secara khusus untuk menangani permasalahan data berurutan atau *time series* dan mengatasi kelemahan utama pada RNN standar, yaitu masalah *vanishing gradient* (hilangnya gradien) yang sering terjadi ketika jaringan dilatih menggunakan data dengan ketergantungan jangka panjang. Jika RNN tradisional hanya memiliki struktur internal yang sederhana berupa satu lapisan *tanh*, LSTM memiliki struktur yang lebih kompleks berupa blok memori yang memungkinkannya mempelajari hubungan antar data dalam deret waktu secara lebih efektif. Kemampuan ini menjadikan LSTM sangat andal dalam memodelkan data historis yang memiliki volatilitas tinggi, seperti harga saham atau komoditas [47].

Kunci utama dari arsitektur LSTM terletak pada sel memori (*memory cell*) dan mekanisme gerbang (*gate*) yang mengatur aliran informasi. Terdapat tiga gerbang utama dalam satu sel LSTM, yaitu *forget gate* (gerbang lupa), *input gate* (gerbang input), dan *output gate* (gerbang keluaran). Mekanisme ini memungkinkan jaringan untuk memutuskan informasi mana yang relevan untuk disimpan dan mana yang harus dibuang, sehingga dapat menjaga ketergantungan jangka panjang [47].



Gambar 2.6 Arsitektur LSTM [48]

Proses pertama dalam sel LSTM terjadi di *forget gate*. Gerbang ini berfungsi untuk menentukan informasi apa yang akan dibuang dari keadaan sel (*cell state*) sebelumnya. *Forget gate* menerima input dari *output* sebelumnya (h_{t-1}) dan input saat ini (x_t), lalu

mengolahnya menggunakan fungsi aktivasi *sigmoid*. Nilai keluaran yang mendekati 0 berarti informasi akan dilupakan, sedangkan nilai mendekati 1 berarti informasi akan disimpan. Secara matematis, persamaan untuk *forget gate* adalah sebagai berikut [47]

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \dots\dots\dots(2.7)$$

Dimana f_t adalah nilai keluaran *forget gate*, σ adalah fungsi sigmoid, W_f adalah bobot, dan b_f adalah bias.

Langkah selanjutnya adalah memperbarui informasi dalam sel melalui *input gate*. Tahap ini melibatkan dua proses: pertama, *input gate* (menggunakan sigmoid) menentukan nilai mana yang akan diperbarui; kedua, sebuah lapisan *tanh* menciptakan vektor kandidat nilai baru ($\tilde{C}_t$) yang berpotensi ditambahkan ke dalam *cell state*, dengan persamaan berikut [47] :

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \dots\dots\dots(2.8)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \dots\dots\dots(2.9)$$

Dimana i_t adalah keluaran *input gate* dan $\tilde{C}_t$ adalah kandidat *cell state* baru.

Setelah mendapatkan nilai dari *forget gate* dan *input gate*, sel LSTM melakukan pembaruan keadaan sel dari C_{t-1} menjadi C_t . Proses ini dilakukan dengan mengalikan *forget gate* dengan *cell state* sebelumnya, kemudian menjumlahkannya dengan hasil perkalian antara nilai *input gate* dan kandidat *cell state* baru dengan persamaan berikut [47]:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \dots\dots\dots(2.10)$$

Tahap terakhir adalah menentukan keluaran dari sel melalui *output gate*. Keluaran ini didasarkan pada keadaan sel yang telah diperbarui namun disaring terlebih dahulu. *Output gate* memutuskan bagian mana dari keadaan sel yang akan dikeluarkan menggunakan fungsi *sigmoid*. Kemudian, *cell state* (C_t) diproses melalui fungsi *tanh* (agar nilainya berada di antara -1 dan 1) dan dikalikan dengan keluaran dari gerbang sigmoid tersebut untuk menghasilkan *hidden state* h_t baru dengan persamaan [47]:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \dots\dots\dots(2.11)$$


$$h_t = o_t * \tanh(C_t) \dots\dots\dots(2.12)$$

Dimana o_t adalah keluaran *output gate* dan h_t adalah hasil prediksi atau *hidden state* pada waktu t .

2.8 Hybrid CNN-LSTM

Model *Hybrid CNN-LSTM* adalah arsitektur *deep learning* yang menggabungkan kemampuan ekstraksi fitur spasial atau pola lokal dari *Convolutional Neural Network* (CNN)

dengan kemampuan pembelajaran ketergantungan sekuensial jangka panjang dari *Long Short-Term Memory* (LSTM). Pada analisis deret waktu finansial, data historis sering kali memiliki volatilitas tinggi dan dipenuhi dengan gangguan. Penggunaan model hibrida ini bertujuan untuk mengatasi kompleksitas tersebut dengan memanfaatkan keunggulan dari masing-masing arsitektur pembentuknya secara berurutan [49].



Gambar 2.7 Arsitektur Hybrid CNN-LSTM [49]

Secara struktural, arsitektur ini terdiri dari dua blok utama. Blok pertama yaitu lapisan *1D-CNN* bertindak sebagai ekstraktor fitur, sedangkan blok kedua yaitu lapisan LSTM bertindak sebagai pemodel sekuensial yang kemudian diakhiri dengan *dense layer* atau *output layer* untuk menghasilkan *output* prediksi tunggal. Pada tahap ekstraksi fitur lokal, data deret waktu diproses dalam lapisan *1D-CNN* terlebih dahulu. Pada tahap ini, filter konvolusi bergeser di sepanjang sumbu waktu untuk mengidentifikasi pola tren, momentum pergerakan harga, sekaligus menyaring gangguan. *Output* dari lapisan konvolusi ini kemudian dapat diproses lebih lanjut secara opsional oleh lapisan *pooling* [49][50]. Penggunaan lapisan *pooling* ini bersifat opsional karena proses reduksi dimensi yang dilakukannya berisiko menghilangkan informasi frekuensi kerusakan yang krusial serta berpotensi memunculkan frekuensi palsu akibat efek *aliasing* [51]

Representasi data yang telah diekstraksi kemudian diteruskan ke dalam blok LSTM untuk proses pembelajaran ketergantungan temporal. Karena data yang masuk sudah dalam keadaan lebih bersih karena hasil pemrosesan oleh CNN, lapisan LSTM dapat bekerja jauh lebih optimal dan efisien dalam mengingat serta memodelkan ketergantungan historis jangka panjang dari pergerakan nilai tukar uang tersebut. Sebagai tahap akhir, *output* atau *hidden State* terakhir dari blok LSTM disalurkan ke dalam *Dense layer*. Lapisan ini bertugas

mengagregasi seluruh pola temporal yang telah dipelajari untuk memetakan hasil akhirnya menjadi sebuah estimasi nilai di masa depan [49].

2.9 Metrik Evaluasi

Untuk mengukur tingkat akurasi dan konsistensi hasil prediksi dari model yang diusulkan, penelitian ini menggunakan beberapa metrik evaluasi statistik standar. Pemilihan metrik ini bertujuan untuk menentukan seberapa baik model dalam mengantisipasi hasil target serta untuk menunjukkan presisi ramalan dibandingkan dengan nilai aktualnya. Tiga metrik utama yang digunakan dalam evaluasi ini adalah *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE).

Mean Absolute Error (MAE) digunakan untuk menghitung rata-rata selisih absolut antara nilai sebenarnya (*observed value*) dan nilai yang diprediksi (*projected value*). Metrik ini memberikan gambaran mengenai besaran kesalahan rata-rata tanpa memperhatikan arah kesalahan tersebut. Persamaan matematis untuk menghitung MAE adalah sebagai berikut [52]:

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - x_j| \dots \dots \dots (2.13)$$

Root Mean Squared Error (RMSE) digunakan untuk memberikan wawasan lebih lanjut mengenai variasi prediksi. RMSE merupakan akar kuadrat dari rata-rata kesalahan kuadrat. Karena menggunakan pengkuadratan sebelum diakarkan, metrik ini memberikan penalti yang lebih besar terhadap kesalahan yang signifikan, sehingga sangat berguna untuk melihat seberapa besar penyimpangan data hasil prediksi. Persamaan matematis untuk menghitung RMSE adalah sebagai berikut [52]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - x_j)^2} \dots \dots \dots (2.14)$$

Mean Absolute Percentage Error (MAPE) digunakan untuk menampilkan presisi peramalan dalam bentuk persentase. Metrik ini menunjukkan rata-rata kesalahan absolut relatif terhadap nilai aktualnya, yang memudahkan interpretasi akurasi model dalam konteks proporsional. Persamaan untuk menghitung MAPE adalah [52]:

$$MAPE = \frac{100\%}{n} \sum_{j=1}^n \left| \frac{y_j - x_j}{y_j} \right| \dots \dots \dots (2.15)$$

Dalam ketiga persamaan di atas, x_j merepresentasikan nilai prediksi, y_j adalah nilai aktual, dan n adalah jumlah total data.

2.10 Uang

Uang didefinisikan secara fundamental bukan hanya sebagai alat tukar, tetapi sebagai instrumen ekonomi yang nilainya sangat bergantung pada mekanisme penegakan kelangkaan (*scarcity enforcement*). Secara ontologis, uang dianggap sebagai aset bernilai jika terdapat lembaga atau sistem yang kredibel dalam menjamin bahwa jumlahnya tidak dapat direplikasi secara bebas tanpa biaya. Dalam sistem moneter modern, stabilitas ini dikelola melalui dua rezim utama: Rezim Institusional (uang fiat) yang kelangkaannya dijaga oleh otoritas pusat seperti bank sentral melalui instrumen kebijakan moneter, dan Rezim Algoritmik yang menggunakan aturan matematis deterministik untuk membatasi pasokan secara otomatis. Kepercayaan masyarakat untuk menerima uang dalam pertukaran barang atau jasa riil sangat didasarkan pada ekspektasi bahwa batasan kelangkaan tersebut akan terus ditegakkan secara konsisten di masa depan guna mempertahankan daya belinya [53].

Dalam konteks ekonomi internasional, perbedaan mata uang antarnegara memunculkan kebutuhan akan nilai tukar (kurs) sebagai jembatan dalam perdagangan dan investasi global [37]. Namun, nilai uang ini sering kali mengalami fluktuasi yang dipengaruhi oleh faktor internal seperti inflasi, suku bunga, dan cadangan devisa, maupun faktor eksternal seperti arus modal asing [3]. Ketidakstabilan nilai tukar, khususnya depresiasi mata uang domestik terhadap valuta asing, tidak hanya menjadi sinyal penurunan aktivitas ekonomi atau potensi resesi [39], tetapi juga memberikan tekanan langsung pada sektor riil. Hal ini terbukti dengan meningkatnya biaya impor dan menurunnya margin keuntungan pada perusahaan ekspor-impor, yang pada akhirnya dapat mengganggu arus kas serta daya saing perusahaan di pasar global [2].

Oleh karena itu, menjaga stabilitas nilai uang melalui kebijakan moneter yang disiplin merupakan instrumen preventif yang vital bagi ketahanan ekonomi nasional [3] [38]. Bank sentral memainkan peran krusial melalui intervensi di pasar valuta asing dan pengelolaan suku bunga untuk meredam volatilitas pasar [3]. Di sisi lain, pelaku ekonomi juga perlu menerapkan strategi manajemen risiko keuangan, seperti penggunaan instrumen derivatif melalui *hedging* (lindung nilai) berupa kontrak *forward* atau opsi valuta asing, guna memitigasi ketidakpastian harga kontrak [2]. Dengan demikian, peramalan nilai tukar yang akurat menjadi sangat penting sebagai dasar pengambilan keputusan strategis, baik bagi pemerintah dalam merumuskan kebijakan moneter maupun bagi sektor swasta dalam menjaga stabilitas keuangan operasional mereka [37] [38] [39].

2.11 Nilai Tukar (*Exchange Rate*)

Nilai tukar mata uang atau kurs merupakan manifestasi eksternal dari nilai uang yang dipengaruhi oleh mekanisme pasar dan kebijakan moneter, serta menjadi komponen penting dalam menjaga kestabilan ekonomi suatu negara [38]. Secara definitif, nilai tukar adalah nilai mata uang suatu negara yang dinyatakan dalam unit mata uang negara lain, atau harga mata uang dalam negeri untuk membeli satu unit mata uang asing. Mengingat setiap negara memiliki mata uang dengan otoritas yang berbeda, proses penukaran mata uang ini menjadi krusial untuk mempermudah transaksi internasional, seperti kegiatan perdagangan dan investasi antarnegara [37].

Perubahan kurs antara rupiah dan dolar Amerika Serikat (USD) memiliki pengaruh besar terhadap kebijakan moneter, investasi, dan perdagangan internasional [38]. Di pasar valuta asing, terdapat dua jenis perubahan nilai mata uang, yaitu apresiasi dan depresiasi. Apresiasi adalah kondisi meningkatnya kekuatan nilai mata uang dalam negeri terhadap mata uang asing, sedangkan depresiasi adalah penurunan nilai mata uang dalam negeri terhadap mata uang asing [39]. Pelemahan nilai rupiah atau depresiasi yang berlebihan dapat menjadi sinyal terjadinya penurunan aktivitas ekonomi atau resesi ekonomi. Oleh karena itu, informasi mengenai perubahan nilai tukar di masa depan sangat diperlukan melalui proses peramalan (*forecasting*) sebagai instrumen preventif [39]. Nilai tukar rupiah terhadap dolar AS sering menjadi acuan utama karena dolar AS merupakan mata uang yang paling umum digunakan dalam transaksi global (*global reserve currency*) [37]. Fluktuasi nilai ini dipengaruhi oleh faktor-faktor kompleks yang saling terkait, seperti tingkat pertumbuhan ekonomi, tingkat inflasi, dan arus modal antarnegara [39]. Karena sifat datanya yang merupakan deret waktu (*time series*) yang sangat fluktuatif, non-linear, dan sulit diprediksi secara manual, penggunaan model komputasi tingkat lanjut diperlukan untuk mendapatkan hasil prediksi yang akurat guna meminimalisir risiko kerugian akibat ketidakpastian ekonomi di masa mendatang [38] [39].

2.11.1 Faktor-Faktor yang Mempengaruhi Nilai Tukar

Pergerakan nilai tukar merupakan fenomena kompleks yang dipengaruhi oleh berbagai variabel moneter dan makroekonomi. Berdasarkan penelitian terbaru, faktor-faktor utama yang secara konsisten memengaruhi kurs rupiah terhadap dolar AS meliputi inflasi, jumlah uang beredar (M2), suku bunga acuan (*BI Rate*), serta harga komoditas global [36] [54]. Ketidakstabilan pada variabel-variabel tersebut dapat memicu depresiasi mata uang yang berdampak pada peningkatan biaya utang luar negeri dan ketidakpastian iklim investasi

[37] [55]. Oleh karena itu, pemahaman terhadap dinamika faktor-faktor ini menjadi landasan penting dalam pengembangan model prediksi yang akurat.

Selain faktor moneter internal, dinamika nilai tukar Rupiah sangat dipengaruhi oleh variabel eksternal dan indikator pasar modal yang merefleksikan sentimen global serta kondisi neraca perdagangan. Harga minyak mentah dunia, seperti *West Texas Intermediate* (WTI), menjadi faktor krusial karena kenaikannya cenderung memicu depresiasi rupiah akibat pembengkakan biaya impor migas dan tekanan pada neraca pembayaran [54]. Sejalan dengan itu, harga emas sebagai instrumen *safe haven* mencerminkan tingkat ketidakpastian global; fluktuasi harga emas sering kali beriringan dengan pergerakan kurs karena investor cenderung mengalihkan aset ke emas saat nilai tukar dolar AS mengalami volatilitas tinggi [56]. Di sisi domestik, Indeks Harga Saham Gabungan (IHSG) memiliki hubungan kausalitas yang kuat dengan nilai tukar, di mana penguatan IHSG sering kali menjadi sinyal aliran modal asing masuk (*capital inflow*) yang memperkuat posisi rupiah terhadap dolar AS [15]. Integrasi ketiga variabel ini memberikan cakupan data yang komprehensif bagi model *deep learning* seperti CNN-LSTM dalam menangkap pola non-linear dan ketergantungan jangka panjang pada pergerakan nilai tukar [15] [36] [54].

2.11.2 Hubungan Harga Minyak Mentah (WTI) terhadap Nilai Tukar

Harga minyak mentah dunia, khususnya jenis *West Texas Intermediate* (WTI), memiliki pengaruh yang signifikan terhadap fluktuasi nilai tukar Rupiah. Hasil analisis menunjukkan bahwa dalam jangka pendek, pergerakan harga minyak WTI berpengaruh negatif terhadap nilai tukar; artinya, kenaikan harga minyak cenderung diikuti oleh penguatan atau pelemahan kurs tergantung pada kondisi neraca perdagangan dan subsidi energi nasional pada periode tersebut. Sebagai variabel eksternal, harga minyak WTI menjadi indikator tekanan global yang dapat memengaruhi cadangan devisa dan stabilitas moneter dalam negeri secara cepat [37] [55].

Dampak harga minyak WTI terhadap nilai tukar Rupiah berkaitan erat dengan struktur ekonomi Indonesia sebagai negara yang memiliki ketergantungan pada impor minyak mentah untuk memenuhi kebutuhan energi domestik. Kenaikan harga WTI di pasar internasional secara langsung meningkatkan beban biaya impor migas, yang jika tidak diimbangi dengan ekspor komoditas lain, akan memperlebar defisit neraca transaksi berjalan dan menguras cadangan devisa [54]. Kondisi ini menciptakan tekanan depresiasi pada nilai tukar rupiah karena meningkatnya permintaan terhadap dolar AS untuk keperluan transaksi impor tersebut. Selain itu, fluktuasi harga minyak juga memicu transmisi inflasi melalui

kenaikan biaya transportasi dan produksi, yang pada gilirannya memaksa otoritas moneter untuk menyesuaikan suku bunga guna menjaga stabilitas kurs [55]. Oleh karena itu, variabel WTI merupakan indikator risiko eksternal yang sangat dinamis dalam model prediksi, mengingat sifatnya yang mampu memengaruhi sentimen pasar dan stabilitas makroekonomi secara simultan.

Dalam konteks penelitian ini, pembahasan mengenai hubungan harga minyak mentah WTI terhadap nilai tukar rupiah disajikan sebagai landasan teoretis untuk memahami pengaruh faktor eksternal terhadap pergerakan nilai tukar. Teori ini memberikan dasar konseptual mengenai bagaimana fluktuasi harga komoditas global dapat memengaruhi stabilitas nilai tukar suatu negara. Oleh karena itu, kajian pada subbab ini bersifat fundamental sebagai dasar pemahaman sebelum variabel tersebut digunakan dalam proses pemodelan dan analisis pada penelitian ini.

2.11.3 Hubungan Harga Emas Dunia terhadap Nilai Tukar

Emas dipandang sebagai instrumen investasi yang stabil dan berfungsi sebagai *safe haven* atau penyimpan nilai (*store of value*) di tengah ketidakpastian ekonomi global. Terdapat kaitan erat antara nilai tukar rupiah dengan harga emas, di mana fluktuasi kurs sering kali menjadi pendorong utama perubahan harga emas domestik. Dalam perspektif pengelolaan harta, emas digunakan oleh investor untuk memitigasi risiko kerugian akibat depresiasi mata uang rupiah terhadap dolar AS, sehingga pergerakan keduanya cenderung memiliki pola ketergantungan yang kuat dalam data runtun waktu [56].

Karakteristik harga emas yang memiliki volatilitas tinggi menjadikannya objek yang kompleks untuk dianalisis, terutama ketika berinteraksi dengan variabel makroekonomi seperti nilai tukar. Secara empiris, nilai tukar rupiah terbukti memiliki pengaruh signifikan terhadap pembentukan harga emas di Indonesia, di mana pelemahan rupiah terhadap dolar AS sering kali memicu lonjakan harga emas domestik sebagai bentuk penyesuaian nilai [56]. Keterkaitan yang dinamis dan bersifat non-linear antara kedua variabel ini menuntut penggunaan metode komputasi yang canggih untuk menghasilkan prediksi yang akurat. Dalam konteks ini, penggunaan model hibrida *deep learning* seperti CNN-LSTM menjadi relevan karena lapisan *Convolutional Neural Network* (CNN) mampu mengekstraksi fitur-fitur penting dari fluktuasi harga, sementara lapisan *Long Short-Term Memory* (LSTM) efektif dalam menangkap ketergantungan jangka panjang serta pola musiman dalam data runtun waktu harga emas dan kurs [9]. Dengan mengintegrasikan nilai tukar sebagai variabel

pendukung, model CNN-LSTM diharapkan dapat meminimalkan nilai *error* prediksi dan membantu investor dalam mengantisipasi risiko pasar di masa depan [9] [56].

Dalam konteks penelitian ini, pembahasan mengenai hubungan harga emas dunia terhadap nilai tukar disajikan sebagai landasan teoretis untuk memahami keterkaitan antara variabel makroekonomi dan pergerakan nilai tukar. Teori ini memberikan dasar konseptual mengenai bagaimana perubahan harga komoditas global dapat memengaruhi stabilitas nilai tukar suatu negara. Oleh karena itu, pada penelitian ini variabel harga emas dunia digunakan sebagai salah satu variabel input dalam proses pemodelan untuk merepresentasikan pengaruh faktor eksternal terhadap pergerakan nilai tukar Rupiah. Dengan demikian, pembahasan pada subbab ini bersifat fundamental sebagai dasar pemahaman sebelum dilakukan analisis dan pemodelan pada penelitian ini.

2.11.4 Hubungan Indeks Harga Saham Gabungan (IHSG) terhadap Nilai Tukar

Kinerja pasar modal yang direpresentasikan oleh Indeks Harga Saham Gabungan (IHSG) memiliki hubungan simultan dengan stabilitas nilai tukar. Kurs mata uang merupakan salah satu variabel makroekonomi yang secara signifikan memengaruhi kepercayaan investor di bursa saham. Stabilitas nilai tukar Rupiah menciptakan sentimen positif yang dapat mendorong kenaikan IHSG, sementara volatilitas kurs yang tinggi cenderung direspon negatif oleh pasar karena meningkatkan risiko sistemik bagi perusahaan tercatat, terutama yang memiliki eksposur utang atau bahan baku dalam mata uang asing [39] [57].

Hubungan antara IHSG dan nilai tukar rupiah juga dapat dijelaskan melalui mekanisme aliran modal asing (*capital flow*), di mana pasar saham sering kali menjadi indikator daya tarik investasi suatu negara. Berdasarkan uji kausalitas, terdapat hubungan dua arah atau saling mempengaruhi antara IHSG dengan nilai tukar rupiah; penguatan indeks saham sering kali diikuti oleh apresiasi mata uang karena meningkatnya permintaan terhadap rupiah oleh investor asing yang masuk ke pasar modal domestik [15]. Sebaliknya, ketika terjadi ketidakpastian ekonomi yang menyebabkan investor menarik modalnya keluar (*capital outflow*), IHSG akan mengalami tekanan koreksi yang secara simultan melemahkan nilai tukar rupiah [15] [58]. Meskipun dalam beberapa periode pengamatan pengaruh nilai tukar secara parsial terlihat tidak dominan terhadap IHSG dibandingkan variabel suku bunga, namun secara simultan keduanya tetap menjadi indikator krusial dalam menentukan stabilitas pasar keuangan nasional [58]. Integrasi variabel IHSG ke dalam model CNN-LSTM menjadi sangat penting karena pergerakan saham mampu menangkap sentimen pasar

yang bersifat *real time*, sehingga dapat memberikan fitur informasi tambahan yang kaya bagi model dalam memprediksi fluktuasi nilai tukar di masa depan.

Dalam konteks penelitian ini, pembahasan mengenai hubungan IHSG terhadap nilai tukar rupiah disajikan sebagai landasan teoretis untuk memahami keterkaitan antara kondisi pasar modal dan pergerakan nilai tukar. Teori ini memberikan dasar konseptual mengenai bagaimana dinamika pasar saham dapat memengaruhi stabilitas mata uang melalui mekanisme aliran modal dan sentimen investor. Oleh karena itu, pada penelitian ini variabel IHSG digunakan sebagai salah satu variabel input dalam proses pemodelan CNN-LSTM untuk merepresentasikan kondisi pasar keuangan domestik. Dengan demikian, pembahasan pada subbab ini bersifat fundamental sebagai dasar pemahaman sebelum dilakukan proses analisis dan pemodelan dalam penelitian.

