

## BAB 2 LANDASAN TEORI

### 2.1 Technical Analysis

Analisis teknikal adalah teknik analisa yang menggunakan data statistika dan tren untuk melakukan prediksi pada pergerakan saham di masa depan [9]. Analisis teknikal didasarkan pada penggunaan tabel, grafik, dan koefisien. Analisis ini bertujuan untuk memperkirakan pergerakan saham baik pada jangka pendek maupun panjang. Analisis teknikal menggunakan harga masa lalu, volume perdagangan, dan data lain yang tersedia di masa lalu untuk mengidentifikasi tren harga yang diyakini bertahan di masa depan[20].

Konsep analisis teknikal pertama kali diperkenalkan oleh Charles Dow. Berdasarkan teori Dow, terdapat dua asumsi dasar yang menjadi kerangka kerja analisis teknis. Asumsi pertama adalah pasar bekerja dengan efisien dalam memproses nilai yang mewakili faktor yang mempengaruhi harga sekuritas, namun pada asumsi kedua, ditekankan bahwa pada pergerakan harga pasar yang acak, dapat ditemukan pola dan tren yang cenderung berulang dari waktu ke waktu [21]. Berdasarkan teori tersebut, pada masa kini terdapat tiga asumsi yang digunakan dalam melakukan analisis teknikal [22]. Asumsi-asumsi tersebut adalah sebagai berikut.

1. Segala sesuatu mulai dari fundamental perusahaan hingga faktor pasar yang luas hingga psikologi pasar sudah diperhitungkan dalam saham.
2. Analisis teknikal memperkirakan bahwa harga, bahkan dalam pergerakan pasar acak, akan menunjukkan tren terlepas dari kerangka waktu yang diamati.
3. Sejarah cenderung berulang dikarenakan adanya kaitan antara pergerakan harga dan psikologi pasar yang cenderung dapat diprediksi berdasarkan emosi.

Dalam analisis teknikal, terdapat beberapa indikator yang dapat dipertimbangkan. Indikator tersebut adalah sebagai berikut.

- *Relative Strength Index (RSI)*

RSI adalah indikator momentum yang digunakan dalam analisis teknis. RSI mengukur kecepatan dan besarnya perubahan harga saham untuk

mengevaluasi kondisi *overvalued*, kondisi dimana harga saham berada diatas nilai intrinsik sesungguhnya, atau *undervalued*, kondisi dimana harga saham berada dibawah nilai intrinsik sesungguhnya, pada harga saham tersebut [23]. Indikator ini ditampilkan pada grafik garis pada skala 0 - 100.

- *Moving Average Convergence/Divergence* (MACD)

MACD adalah indikator momentum yang menunjukkan hubungan antara dua *Exponential Moving Average* (EMA) dari harga sekuritas [24]. EMA adalah salah satu tipe *Moving Average* yang menempatkan bobot dan signifikansi lebih besar pada poin data terbaru. MACD biasa ditampilkan dengan histogram yang menggambarkan jarak antara MACD dan garis sinyalnya. Jika MACD berada di atas garis sinyal, histogram akan berada di atas *baseline* MACD, atau garis nol. Jika MACD berada di bawah garis sinyalnya. Grafik tersebut dapat digunakan untuk mengevaluasi kondisi *overbought/oversold*. *Overbought* adalah kondisi di mana saham diperdagangkan dengan harga yang lebih tinggi daripada nilai intrinsiknya dalam jangka waktu tertentu, sementara *oversold* adalah kondisi di mana saham diperdagangkan dengan harga yang lebih rendah daripada nilai intrinsiknya dalam jangka waktu tertentu.

- *Simple Moving Average* (SMA)

SMA adalah pergerakan rata-rata yang dihitung dengan menambahkan harga terkini dan kemudian membagi angka tersebut dengan jumlah periode waktu dalam perhitungan rata-rata. SMA memudahkan observasi tren harga saham. Jika rata-rata pergerakan sederhana naik, ini berarti harga sekuritas naik. Jika mengarah ke bawah, berarti harga saham sedang turun [25].

## 2.2 Indeks LQ45

Indeks pasar saham merupakan suatu angka statistik yang mencerminkan perubahan harga secara keseluruhan dari sekelompok saham yang telah dipilih berdasarkan kriteria dan metode tertentu, dan diuji secara berkala untuk mengevaluasi perubahannya [16]. Indeks pasar saham dapat digunakan untuk mengukur sentimen pasar atau kepercayaan investor, acuan produk investasi, *benchmark* portofolio aktif, proksi dalam mengukur dan membuat model pengembalian investasi, risiko sistematis, dan kinerja yang disesuaikan dengan risiko, serta proksi untuk kelas aset dalam alokasi aset [26]. Salah satu indeks yang

dikelola oleh PT BEI adalah indeks LQ45. Indeks ini mengukur kinerja harga dari 45 saham yang memiliki likuiditas tinggi, kapitalisasi pasar besar, dan fundamental perusahaan yang baik, sehingga indeks ini biasa digunakan sebagai acuan untuk melacak tren kinerja pasar saham.

Pada indeks LQ45, saham dipilih berdasarkan kinerja 80 saham pada indeks saham IDX 80 dengan mempertimbangkan faktor likuiditas, seperti nilai transaksi, frekuensi transaksi, hingga jumlah hari transaksi, serta faktor fundamental seperti kinerja keuangan [26]. Indeks LQ45 ditinjau secara berkala. Tinjauan utama dilakukan pada bulan Januari dan Juli, sedangkan tinjauan tambahan dilakukan pada bulan April dan Oktober. Berdasarkan komposisinya, indeks LQ45 terdiri dari saham yang berasal dari sektor-sektor ekonomi yang penting dan memiliki potensi pertumbuhan yang tinggi, sehingga indeks LQ45 dapat memberikan gambaran umum tentang kesehatan ekonomi negara dan sentimen pasar secara keseluruhan. Salah satu sektor yang tergabung dalam indeks LQ45 adalah sektor infrastruktur. Sektor ini mencakup perusahaan yang bergerak pada bidang konstruksi, energi, transportasi, utilitas, dan telekomunikasi. Berdasarkan laporan evaluasi Februari-Juli 2023, sektor infrastruktur indeks LQ45 terdiri dari PT XL Axiata Tbk, PT Telkom Indonesia (Persero) Tbk, PT Tower Bersama Infrastructure Tbk, dan PT Sarana Menara Nusantara TBK.

### 2.3 Machine Learning


*Machine learning* adalah bidang studi yang menggunakan algoritma komputasi untuk mengubah data empiris menjadi model yang dapat digunakan [27]. Algoritma *machine learning* dapat digunakan untuk mengumpulkan pemahaman tentang fenomena dunia maya untuk menghasilkan data yang akan dipelajari, mengabstraksikan pemahaman tentang fenomena yang menjadi dasar bentuk model, memprediksi nilai masa depan fenomena dengan menggunakan model yang telah dibentuk, serta mendeteksi perilaku anomali pada fenomena yang diamati. Pembelajaran mesin dapat dikategorikan menjadi *Supervised Learning*, yaitu model pembelajaran yang dibangun untuk membuat prediksi, dengan memberikan contoh input yang tidak terduga, *Unsupervised Learning*, yaitu model pembelajaran yang dibangun untuk menemukan keteraturan dalam masukan sedemikian rupa sehingga pola tertentu terjadi lebih sering daripada yang lain dan untuk belajar melihat apa yang umumnya terjadi dan apa yang tidak, *Semi-supervised Learning*, yaitu model pembelajaran yang dibangun untuk mengklasifikasikan beberapa data yang tidak

berlabel menggunakan kumpulan informasi berlabel, dan *Reinforcement Learning*, yaitu model yang membahas masalah bagaimana agen otonom yang merasakan dan bertindak dalam lingkungannya dapat belajar untuk memilih tindakan yang optimal untuk mencapai tujuannya [28].

Salah satu subbidang dari *machine learning* adalah *deep learning*. *Deep learning* memungkinkan mesin untuk mencapai kinerja seperti manusia dalam banyak tugas kognitif yang kompleks [29]. *Deep learning* merupakan metode pembelajaran dimana komputasi dilakukan melalui jaringan dan pemrosesan saraf berlapis-lapis. Istilah "*deep*" yang digunakan mengacu pada level atau tahapan di mana data diproses untuk membangun model [30]. Awalnya, *Artificial Neural Network* hanya terdiri dari 2 layer, yaitu *input layer* yang dianalogikan sebagai input sensorik manusia dan *output layer* yang dianalogikan sebagai reaksi otot. Desain ini memiliki kelemahan dalam memproses data ketika respons keluaran secara signifikan nonlinier dengan masukan, oleh karena itu ditambahkan lapisan baru diantara *input* dan *output* yaitu *hidden layer*. *Hidden layer* bertanggung jawab untuk mentransformasi data input melalui serangkaian operasi nonlinier, yang memungkinkan jaringan syaraf untuk belajar dan menangkap pola dan hubungan yang kompleks dalam data [31].

## 2.4 Recurrent Neural Networks

*Recurrent Neural Networks* (RNN) merupakan salah satu *deep learning model* [30]. RNN adalah *neural network* dengan memori yang mampu menangkap semua informasi yang disimpan secara berurutan [32]. RNN terdiri dari banyak lapisan berulang yang berurutan, dan lapisan ini dimodelkan secara berurutan untuk memetakan urutan dengan urutan lainnya [33]. RNN bekerja dengan menggunakan hasil dari output saat ini sebagai input untuk output berikutnya. Kemampuan RNN untuk menyimpan kalkulasi terdahulu menyebabkan RNN secara alami cocok untuk mengelola data deret waktu ataupun data berurut lainnya. Gambar 2.1 menggambarkan alur kerja dari RNN [33].



Gambar 2.1. Alur kerja RNN

## 2.5 Long Short-Term Memory

*Long short-term memory* (LSTM) merupakan salah satu tipe RNN. LSTM hadir sebagai solusi untuk mengatasi kelemahan RNN yang dapat mengalami kehilangan nilai gradien yang dapat timbul selama proses pembelajaran RNN [34]. LSTM terdiri dari beberapa komponen utama, yaitu *cell state*, *input gate*, *output gate*, *forget gate*, dan *hidden state*. *Cell state* merupakan tempat memori dari LSTM dan digunakan untuk menyimpan informasi. *Input gate* digunakan untuk menentukan informasi-informasi yang akan perlu dimasukkan kedalam *cell state*. *Output gate* menentukan informasi yang perlu diteruskan ke *hidden state* berikutnya. *Forget gate* digunakan untuk menentukan informasi yang perlu dibuang dan perlu dipertahankan [35].

Beberapa persamaan yang digunakan dalam LSTM adalah sebagai berikut [34].

$$f_t = \sigma(W_{fh}h_{t-1} + W_{fx}x_t + b_f) \quad (2.1)$$

$$i_t = \sigma(W_{ih}h_{t-1} + W_{ix}x_t + b_i) \quad (2.2)$$

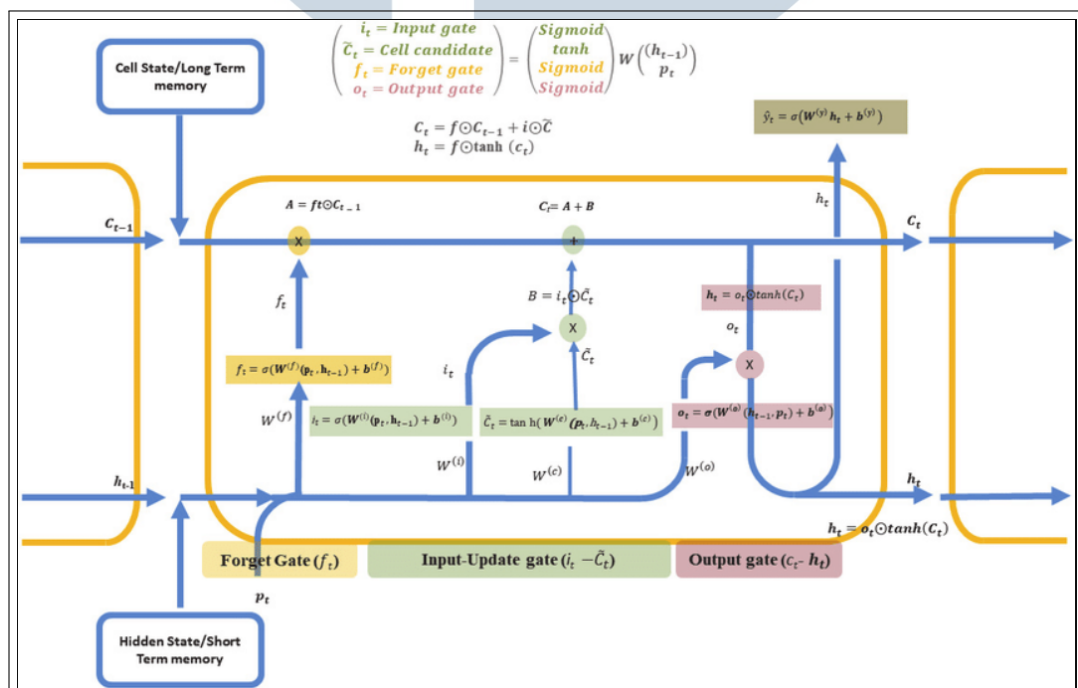
$$o_t = \sigma(W_{oh}h_{t-1} + W_{ox}x_t + b_o) \quad (2.3)$$

$$\tilde{c}_t = \tanh(W_{ch}h_{t-1} + W_{cx}x_t + b_c) \quad (2.4)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (2.5)$$

$$h_t = o_t \odot \tanh(c_t) \quad (2.6)$$

Pada persamaan diatas,  $f_t$  adalah nilai dari *forget gate* sel,  $i_t$  merupakan nilai dari *input gate* sel,  $o_t$  merupakan nilai dari *output gate* sel,  $c_t$  merupakan nilai kondisi sel saat ini,  $\tilde{c}_t$  merupakan nilai sel kandidat,  $W$  merupakan nilai *weight* dari jaringan,  $b$  melambangkan bias dalam jaringan dan  $h_t$  merupakan nilai dari *hidden state*. Gambar 2.2 menggambarkan arsitektur dari sel LSTM [36].



Gambar 2.2. Arsitektur sel LSTM

## 2.6 Kriteria Error

Dalam pembelajaran mesin, kriteria error memiliki peranan penting dalam proses evaluasi model. Kriteria error berperan dalam mengkalibrasi atau menyempurnakan model yang bertujuan untuk memastikan akurasi model dalam memprediksi [37]. Kriteria error mengukur perbedaan antara keluaran model yang diprediksi dan label sebenarnya atau nilai target dalam data pelatihan. Dalam menentukan kesalahan sebuah model terdapat berbagai metode yang dapat digunakan pada rangkaian tertentu. Beberapa metode yang populer untuk digunakan dalam prediksi seri waktu adalah RMSE dan MAPE.

### 2.6.1 Mean Absolute Percentage Error

*Mean Absolute Percentage Error* merupakan nilai persentase dari *Mean Absolute Error* yang biasa digunakan sebagai metrik evaluasi kinerja model [38]. MAPE merepresentasikan persentase kesalahan absolut dari setiap entri data yang menunjukkan rata-rata akurasi data prediksi dan data asli. Nilai MAPE dapat digunakan untuk menginterpretasikan akurasi dari model [39]. Tabel 2.1 merupakan interpretasi akurasi model berdasarkan nilai MAPE.

Tabel 2.1. Interpretasi Nilai MAPE

| MAPE  | Interpretasi                 |
|-------|------------------------------|
| <10   | Peramalan yang sangat akurat |
| 10-20 | Peramalan yang baik          |
| 20-50 | Peramalan yang wajar         |
| >50   | Peramalan yang kurang akurat |

Rumus dari MAPE adalah sebagai berikut.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{actual(i) - predicted(i)}{actual(i)} \right| \times 100\% \quad (2.7)$$

### 2.6.2 Root Mean Squared Error

*Root mean squared error* merupakan nilai akar kuadrat dari *Mean Squared Error*, yaitu kesalahan kuadrat rata-rata antara nilai prediksi dan aktual, yang biasa

digunakan sebagai metrik evaluasi kinerja model [38]. Berdasarkan hal tersebut, maka semakin kecil nilai RMSE, semakin baik kinerja model dalam melakukan prediksi. Rumus dari RMSE adalah sebagai berikut.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (actual(i) - predicted(i))^2}{n}} \quad (2.8)$$

## 2.7 Value at Risk

*Value at risk* (VaR) adalah sebuah nilai yang digunakan untuk melaporkan kerugian maksimum dari memegang suatu aset selama periode tertentu pada tingkat probabilitas tertentu [40]. VaR merupakan salah satu metode pengukuran risiko yang biasa digunakan dalam manajemen risiko keuangan untuk memperkirakan kerugian maksimum yang dapat terjadi pada suatu investasi. Pemodelan VaR menentukan potensi kerugian dalam entitas yang dinilai dan probabilitas bahwa kerugian yang ditentukan akan terjadi. VaR sering digunakan dalam pengukuran risiko dikarenakan hasilnya yang berupa 1 angka sehingga mudah untuk dimengerti dan komputasinya yang dapat dilakukan pada tipe-tipe aset yang berbeda.

VaR dinilai berdasarkan jumlah potensi kerugian, probabilitas terjadinya jumlah kerugian, dan kerangka waktu [41]. Dalam perhitungan VaR terdapat berbagai cara yang dapat digunakan, salah satunya adalah melalui metode parametrik. Metode parametrik mempertimbangkan estimasi rata-rata dan standar deviasi dari distribusi normal serta nilai terkait  $Z(\alpha)$  [42]. Rumus parametric dari VaR adalah sebagai berikut.

$$VaR = \mu - z_{\alpha}\sigma \quad (2.9)$$

Pada persamaan tersebut,  $\mu$  adalah return harian rata-rata,  $z_{\alpha}$  adalah z-score pada tingkat kepercayaan tertentu, dan  $\sigma$  adalah standar deviasi return harian.