

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Tabel 2. 1 Penelitian Terdahulu

	Judul Jurnal	Nama Jurnal	Penulis/Tahun	Metode	Hasil
1	Perbandingan Kinerja Metode Linear Regression, LSTM dan GRU untuk Prediksi Harga Penutupan Saham Coca-Cola[11]	Komputika: Jurnal Sistem Komputer Volume 13, Nomor 2	Rosalia Natal Silalahi, Muljono/2024	Linear Regression, Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU)	Penelitian ini membandingkan akurasi model Linear Regression, LSTM, dan GRU dalam memprediksi harga penutupan saham Coca-Cola dengan variasi window-width. Hasilnya, Linear Regression paling akurat (MSE 0.21, RMSE 0.46, MAE 0.29) pada window-width 3 dan 5. GRU menyusul dengan performa terbaik di window-width 5 (MSE 0.23, RMSE 0.48, MAE 0.31), sementara LSTM memiliki akurasi terendah (MSE 1.94, RMSE 1.39, MAE 0.94) pada window-width 5.
2	<i>A CNN-LSTM-Based Model to Forecast Stock Prices</i> [12]	<i>Hindawi Complexity</i> Volume 2020, Article ID 6622927	Wenjie Lu, Jiazheng Li, Yifan Li, Aijun Sun, Jingyang Wang/2020	CNN (Convolutional Neural Network), LSTM (Long Short-Term Memory)	Prediksi harga saham sangat penting untuk investasi, namun metode yang berbeda menghasilkan akurasi yang bervariasi. Penelitian ini

				<p>membandingkan Linear Regression, LSTM, dan GRU untuk menemukan metode terbaik. Linear Regression dengan window-width 3 menunjukkan performa terbaik dengan nilai Mean Squared Error (MSE) sebesar 0.21 dan Root Mean Squared Error (RMSE) sebesar 0.46. Ini lebih baik dibandingkan LSTM (MSE 3.24, RMSE 1.80) dan GRU (MSE 0.40, RMSE 0.64). Linear Regression direkomendasikan untuk prediksi harga saham Coca-Cola karena hasilnya lebih akurat dan sederhana.</p>	
3	<p>Perbandingan Model Long Short-Term Memory, Gated Recurrent Unit, dan Convolutional Neural Network untuk Peramalan Harga Emas[13]</p>	<p>PRISMA 8 (2025): 414-431 PRISMA, Prosiding Seminar Nasional Matematika</p>	<p>Sabrina Aziz Aulia, Ahmad Muhamad Solihin, Rifky Surya Pratama, Ghofari Miftah / 2025</p>	<p>LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit), CNN (Convolutional Neural Network)</p>	<p>Fluktuasi harga emas yang kompleks menyebabkan risiko tinggi dalam investasi. Model prediksi tradisional kurang akurat untuk data non-linear seperti harga emas. Penelitian ini menguji model Deep Learning (LSTM, GRU, CNN) untuk meningkatkan akurasi prediksi. Model GRU menunjukkan efisiensi pelatihan terbaik dan akurasi tertinggi untuk time step 5 (1 minggu) dan 30 (1</p>

				<p>bulan) dengan nilai MAPE lebih kecil dibandingkan model lain. Untuk time step 260 (1 tahun), akurasi GRU dan LSTM hampir sama, keduanya lebih baik daripada CNN. GRU disimpulkan paling efisien dan akurat untuk semua time step dalam peramalan harga emas.</p>
4	<p><i>Stock Prediction Based on Optimized LSTM and GRU Models</i>[14]</p>	<p><i>Hindawi Scientific Programming</i></p>	<p>Ya Gao, Rong Wang, Enmin Zhou / 2021</p>	<p>LSTM (Long Short-Term Memory),GRU (Gated Recurrent Unit)</p> <p>Prediksi harga saham sangat kompleks karena banyak faktor yang memengaruhi, baik dari sisi ekonomi maupun sentimen psikologis investor. Model linier tradisional seperti ARIMA kurang efektif untuk data pasar saham yang non-linear dan berfluktuasi tinggi. Penelitian ini mengembangkan pendekatan dengan LSTM dan GRU serta mengurangi dimensi data input menggunakan LASSO dan PCA untuk meningkatkan akurasi prediksi. Hasil eksperimen menunjukkan bahwa baik LSTM maupun GRU sama-sama efektif dalam memprediksi harga saham, namun model dengan data hasil reduksi</p>

					dimensi LASSO memberikan kinerja lebih baik dibandingkan PCA. Tidak ada perbedaan signifikan antara LSTM dan GRU dalam akurasi, tetapi kombinasi LASSO dengan LSTM atau GRU memberikan hasil terbaik untuk prediksi harga saham.
5	Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM)[15]	Jurnal Nasional Teknologi dan Sistem Informasi	Gunawan Budiprasetyo, Mamluatul Hani'ah, Darin Zahria Aflah/2023	LSTM (Long Short-Term Memory)	Fluktuasi harga saham syariah di pasar membuat prediksi menjadi tantangan bagi investor, terutama karena data time series bersifat kompleks. Metode tradisional seperti ARIMA kurang akurat untuk prediksi jangka panjang. LSTM dipilih karena keunggulannya dalam menangani data sekuensial dan mengatasi masalah vanishing gradient. Model LSTM dengan 8 layer menunjukkan performa prediksi yang lebih baik dengan MAPE rendah pada semua emiten: PT Aneka Tambang Tbk (2,64), Erajaya Swasembada Tbk (2,24), Kalbe Farma Tbk (1,51), Semen Indonesia Tbk (1,83), dan Wijaya Karya Tbk (2,66). Semua hasil MAPE menunjukkan

					performa prediksi yang akurat (<10).
6	<p>Prediksi Harga Saham Bank Central Asia Menggunakan Algoritma Deep Learning GRU[16]</p>	<p>Jurnal Ilmiah Teknik Informatika dan Sistem Informasi</p>	<p>Kurnia Prayogi, Windu Gata, Devy Putri Kussanti / 2024</p>	<p>Gated Recurrent Unit (GRU)</p>	<p>Prediksi harga saham mengalami tantangan karena volatilitas tinggi dan pengaruh sentimen pasar. Analisis teknikal dan fundamental tradisional kurang akurat. Model GRU dipilih karena mampu menangkap pola non-linear dalam data sekuensial dengan lebih sederhana dibandingkan LSTM. Model dengan train-test split 80:20, lookback 15, timestep 15, epoch 50 menghasilkan performa terbaik dengan nilai RMSE 1.039, MSE 1.079, MAE 0.842, R² 0.983, serta accuracy 54.87%, recall 59.23%, F1-score 58.11%, dan precision 57.03%. GRU terbukti efektif dalam memprediksi harga saham Bank Central Asia dengan performa cukup akurat.</p>
7	<p><i>Study on the Prediction of Stock Price Based on the Associated Network Model of LSTM</i>[17]</p>	<p><i>International Journal of Machine Learning and Cybernetics</i></p>	<p>Guangyu Ding, Liangxi Qin / 2020</p>	<p>LSTM (Long Short-Term Memory)</p>	<p>Sebagian besar metode prediksi saham hanya memprediksi satu variabel (misalnya harga penutupan saja). Padahal dalam kenyataan, variabel seperti</p>

				<p>harga pembukaan, tertinggi, dan terendah saling berhubungan. Penelitian ini bertujuan mengembangkan model yang mampu memprediksi beberapa harga sekaligus dalam satu jaringan. Model Associated Network berhasil memberikan akurasi prediksi lebih dari 95% untuk ketiga variabel (harga pembukaan, tertinggi, terendah). Model ini lebih unggul dibanding LSTM biasa maupun DRNN, terutama dalam akurasi prediksi harga tertinggi (highest price). Model efektif untuk menangkap hubungan antar harga dalam data saham.</p>	
8	<p><i>GRU Neural Network Based on CEEMDAN-Wavelet for Stock Price Prediction</i>[18]</p>	<p><i>Applied Sciences (MDPI)</i></p>	<p>Chenyang Qi, Jiaying Ren, Jin Su / 2023</p>	<p>Gated Recurrent Unit (GRU)</p>	<p>Prediksi harga saham menghadapi tantangan karena volatilitas dan noise tinggi dalam data keuangan. Model deep learning biasa (seperti GRU, LSTM) cenderung terganggu oleh noise sehingga akurasi prediksi berkurang. Penelitian ini mengembangkan framework gabungan GRU-</p>

				<p>CEEMDAN–Wavelet untuk memperbaiki masalah noise dan meningkatkan akurasi. Model GRU berbasis CEEMDAN-Wavelet mencapai akurasi tertinggi dibandingkan LSTM, CNN-BiLSTM, ANN, dan ARIMA. R^2 mendekati 0.994 untuk CSI300 dan 0.991 untuk S&P500, menunjukkan prediksi sangat akurat. GRU-CEEMDAN–Wavelet lebih unggul dalam mengurangi error (RMSE dan MAE) dibandingkan semua model perbandingan.</p>
--	--	--	--	---

Seperti isi tabel 2.1 penelitian terdahulu yang ada diatas ini, terdapat jurnal-jurnal yang dijadikan referensi berhubung dengan penelitian yang dilakukan ini. Seluruh jurnal yang ada diatas ini, telah melakukan penelitian dari berbagai kasus yang berbeda, dimulai dari prediksi harga saham, harga emas, dan lainnya dengan menggunakan algoritma yang mirip-mirip, hingga perbandingan algoritma yang digunakan. Selain itu juga, seluruh jurnal yang ada diatas ini, menjadi referensi peneliti untuk pelaksanaan penelitian yang dilakukan yang dimana dengan adanya referensi jurnal tersebut, penelitian ini jadi memiliki arahan dalam pelaksanaan penelitiannya tersebut seperti, apakah metode ini cocok digunakan, apakah alur penelitiannya sudah sesuai, hingga agar tidak terjadi hal yang tidak diinginkan seperti, salah menggunakan metode, model, dan lain-lainnya.

Pada jurnal yang berjudul “Perbandingan Kinerja Metode Linear Regression, LSTM dan GRU untuk Prediksi Harga Penutupan Saham Coca-Cola”, menjadi acuan dan juga gambaran dalam hal prediksi pergerakan saham dengan menggunakan tiga algoritma yang serupa, akan tetapi salah satunya berbeda yaitu menggunakan linear regression sedangkan penelitian ini menggunakan 1D-CNN dan objek penelitiannya pun berbeda[11]. Setelah itu pada referensi jurnal berikutnya, yaitu “*A CNN-LSTM-Based Model to Forecast Stock Prices*”, menjadi referensi untuk penelitian ini dalam melakukan prediksi harga saham dengan algoritma yang serupa. Namun, pada referensi jurnal tersebut, hanya menggunakan dua model algoritma saja yaitu LSTM dan GRU. Walaupun hanya menggunakan dua model saja, tetap bisa menjadi gambaran dalam penelitian ini karena penelitian ini juga menggunakan model algoritma yang sama yang dimana referensi tersebut diambil untuk mengetahui kinerja model tersebut seberapa pengaruhnya dalam melakukan prediksi pergerakan harga saham[12].

Setelah itu, pada jurnal ketiga yang berjudul “Perbandingan Model Long Short-Term Memory, Gated Recurrent Unit, dan Convolutional Neural Network untuk Peramalan Harga Emas”, menjadi referensi si peneliti dengan algoritma yang serupa tapi tidak LSTM dan terlebihnya lagi pada kasus yang berbeda yaitu peramalan harga emas. Dalam referensi jurnal ini, peneliti ingin mengetahui penggunaan algoritma yang digunakan dalam kasus yang berbeda memiliki hasil akhir yang bagus atau tidak[13]. Selanjutnya, untuk jurnal yang berjudul “*Stock Prediction Based on Optimized LSTM and GRU Models*” menjadi referensi peneliti dalam melakukan prediksi pergerakan saham akan tetapi hanya menggunakan LSTM dan GRU saja, tidak ada CNN, dan konsepnya pun berbeda yaitu optimasi. Pada referensi jurnal ini, peneliti ingin mengetahui apakah LSTM dan GRU itu cocok untuk dijadikan perbandingan algoritma atau tidak, yang dimana pemelihan ketiga algoritma yang digunakan dalam penelitian ini berdasarkan setiap referensi-referensi yang diambil agar tidak terjadinya kesalahan pemilihan model dalam penelitian yang dilakukan ini[14].

Pada jurnal yang berjudul “Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM)”, menjadi referensi peneliti dalam

mempelajari kegunaan LSTM secara lebih detail terhadap kegunaannya dalam prediksi harga saham. Selanjutnya, pada jurnal yang berjudul “Prediksi Harga Saham Bank Central Asia Menggunakan Algoritma Deep Learning GRU”, menjadi referensi peneliti dalam mempelajari kegunaan GRU secara lebih detail terhadap kegunaannya dalam prediksi harga saham. Lalu, pada jurnal yang berjudul “*Study on the Prediction of Stock Price Based on the Associated Network Model of LSTM*”, menjadi referensi bagi peneliti bagi LSTM dalam hasil metrik MAPE yang dimana metrik tersebut digunakan dalam penelitian ini. Terakhir, pada jurnal yang berjudul “*GRU Neural Network Based on CEEMDAN–Wavelet for Stock Price Prediction*” menjadi referensi peneliti dalam kegunaannya GRU pada penelitian lainnya.

Seluruh jurnal yang diambil peneliti dalam proses penelitiannya tersebut, menjadi referensi bagi peneliti yang dimana dengan adanya referensi-referensi ini, dapat menjadi bahan pelajaran untuk peneliti agar proses penelitian ini dapat berjalan dengan lancar tidak terjadi hal yang tidak diinginkan seperti, salah menggunakan metode algoritma, metrik yang dipakai tidak sesuai, dan lain-lainnya. Selain itu juga, perbedaan referensi-referensi jurnal dengan penelitian ini adalah objek penelitian yang berbeda dari sebelumnya dan rentang waktu penelitian berbeda yang dimana dari sisi objek penelitian tidak ada yang menggunakan objek subsektor minyak dan gas.

2.2 Tinjauan Teori

2.2.1 PT Perusahaan Gas Negara Tbk (PGAS)

PGAS adalah emitmen gas alam terbesar di Indonesia dengan kapitalisasi pasar sekitar Rp 43 triliun. Perusahaan yang sebelumnya adalah bagian dari PT Pertamina yang kali ini berfokus pada distribusi gas melalui jaringan pipa nasional, termasuk gas kota dan gas untuk industri. PGAS menguasai infrastruktur gas yang vital yang dimana dengan adanya aset seperti transmisi Jawa-Sumatra dan jaringan distribusi di berbagai kota besar. Namun, kinerjanya sangat dipengaruhi oleh kebijakan harga gas domestik dan juga fluktuasi permintaan industri. Dalam beberapa tahun terakhir, PGAS aktif mengembangkan proyek gas untuk pembangkit listrik

(PLTGU) dan kompresi gas alam (LNG), sekaligus menghadapi tantangan transisi energi dengan mengoptimalkan gas sebagai "jembatan" menuju energi bersih[19].

2.2.2 PT Medco Energi Internasional Tbk (MEDC)

MEDC adalah perusahaan energi terintegrasi sesuai dengan kapitalisasi pasar sekitar Rp 32 triliun yang dimana bergerak di eksplorasi dan produksi migas, hingga mulai mengembangkan energi terbarukan. Portofolio MEDC itu sendiri juga mencakup lapangan migas di Indonesia seperti blok riau, aceh, amerika serikat, dan juga timur Tengah. Kinerjanya juga berhubung dengan harga minyak mentah dunia yang dimana dapat meningkatkan dengan signifikan seiring kenaikan harganya. MEDC juga aktif dalam transisi energi melalui akuisisi pembangkit panas bumi seperti sarulla operations, dan juga proyek hidrogen hijau. Keunggulannya terletak pada diversifikasi aset global dan strategi keberlanjutan, meski tetap terpapar risiko volatilitas harga komoditas dan kompleksitas operasi internasional[20].

2.2.3 PT AKR Corporindo Tbk (AKRA)

AKRA adalah perusahaan distribusi dan logistik energi dengan kapitalisasi pasar sekitar Rp23 triliun. Bisnis utamanya yaitu adanya perdagangan bahan bakar minyak (BBM), pelabuhan, dan penyimpanan energi, termasuk distribusi biodiesel. AKRA memiliki infrastruktur strategis seperti Terminal BBM Cilacap dan Dumai, serta menguasai rantai pasok energi di wilayah Jawa-Sumatra. Perusahaan ini relatif lebih stabil dibanding emiten migas murni karena pendapatannya berasal dari margin distribusi, bukan harga komoditas langsung. AKRA juga merespons tren energi hijau dengan mengembmangkan bahan bakar nabati (BBN) dan logistik terbarukan. Tantangan utamanya ialah persaingan ketat dengan Pertamina dan juga ketergantungan pada kebijakan subsidi pemerintah[21].

2.2.4 PT Rukun Raharja Tbk (RAJA)

RAJA adalah emiten dengan kapitalisasi pasar terkecil di antara keempatnya (Rp5 triliun), berfokus pada jasa penunjang migas seperti operasi dan juga pemeliharaan infrastruktur gas serta energi terbarukan. Portofolio RAJA itu sendiri juga mencakup kontrak jangka panjang dengan PGAS dan Pertamina, termasuk

pemeliharaan jaringan pipa gas dan fasilitas kilang. Kinerjanya stabil berkat pendapatan berbasis kontrak, tetapi pertumbuhannya terbatas karena skala bisnis yang kecil dan ketergantungan pada proyek-proyek domestik. RAJA mulai berekspansi ke energi bersih, seperti proyek biogas, namun masih menghadapi tantangan dalam meningkatkan skala bisnis di tengah dominasi pemain besar [22].

2.2.5 Saham Subsektor Minyak dan Gas

Saham subsektor minyak dan gas (migas) adalah sektor energi yang memiliki pengaruh besar terhadap perekonomian nasional dan juga internasional. Subsektor tersebut terdapat perusahaan-perusahaan yang beraktivitas melakukan eksplorasi, produksi, distribusi, hingga pengolahan minyak dan gas alam. Yuliana dan Hartono (2020) menyatakan bahwa harga saham pada subsektor ini sangat terpengaruh oleh fluktuasi harga minyak dunia, kebijakan pemerintah, serta situasi geopolitik[23]. Selain itu, ketinggian volatilitas harga energi juga menyebabkan saham migas rentan terhadap perubahan sentimen pasar. Siregar (2021) menegaskan bahwa analisis teknikal dan fundamental digunakan dalam menghakimi kelayakan investasi di sektor ini[24]. Dengan demikian, pemodelan prediksi harga saham sangat berperan penting dalam melengkapi pengambilan keputusan investasi.

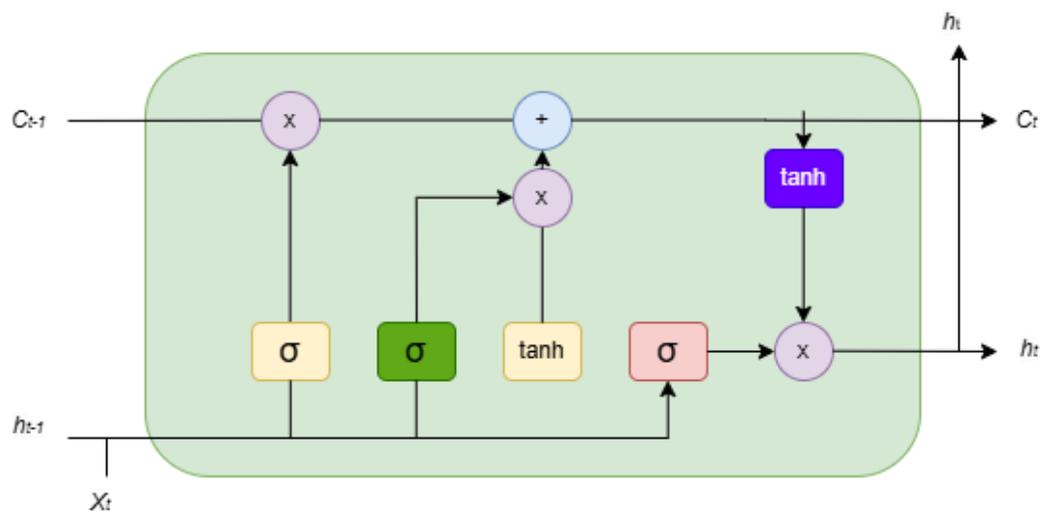
2.2.6 Deep Learning

Deep learning adalah cabang dari machine learning yang meniru cara kerja otak manusia dalam memproses data dan juga membuat pola untuk digunakan dalam pengambilan keputusan. Teknologi ini memanfaatkan jaringan saraf tiruan (artificial neural networks) dengan banyak lapisan (deep neural networks) untuk mengekstraksi fitur kompleks dari data berskala besar. Deep learning telah menunjukkan kinerja unggul dalam berbagai bidang seperti pengenalan gambar, pemrosesan bahasa alami, dan prediksi deret waktu. Keunggulan utama deep learning terletak pada kemampuannya dalam pembelajaran fitur otomatis (feature learning) tanpa perlu ekstraksi manual. Dalam konteks analisis data keuangan, deep learning digunakan untuk mengidentifikasi pola tersembunyi dan memprediksi pergerakan harga secara lebih akurat [25].

2.3 Teori tentang Framework/Algoritma yang digunakan

2.3.1 Long Short Term Memory (LSTM)

Long Short-Term Memory adalah jaringan dari tipe Recurrent Neural Network (RNN) dapat didefinisikan sebagai sebuah jaringan dari tipe Recurrent Neural Network yang memiliki extension, LSTM bertujuan untuk memperluas memori dari yang sebelumnya dimiliki oleh recurrent neural network. Selain itu, LSTM dapat membawa informasi dan membantu mengingat input yang telah diterima pada recurrent neural network dalam periode yang cukup lama, serta dapat mengatasi permasalahan terkait prediksi secara terstruktur [26].



Gambar 2. 1 Proses LSTM

Sumber: [27]

Berdasarkan Gambar 2.1, bisa dilihat, bahwa struktur LSTM mempunyai 3 gerbang, yaitu Forget gate (F_t), Input gate (I_t), Output gate (O_t). Pada gerbang forget gate (F_t). Data akan dikelola dan ditentukan data atau informasi mana yang akan dihapus dari sell menggunakan aktivasi sigmoid. Pada gerbang Input gate (I_t) digunakan untuk memutuskan nilai mana yang akan diperbarui. Sedangkan pada Output gate (O_t) digunakan untuk memutuskan bagian-bagian apa dari konteks yang akan dihasilkan. Selain itu juga, setiap gerbang tersebut juga memiliki rumus itu sendiri:

1. Forget Gate (F_t)

Forget gate adalah komponen dalam struktur LSTM yang dimana bertugas untuk menentukan informasi apa dari memori sebelumnya yang perlu dilupakan [28].

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

Rumus 2. 1 Rumus Forget Gate

Keterangan:

σ = fungsi aktivasi sigmoid

h_{t-1} = *hidden state* sebelumnya

x_t = *input* saat ini

W_f, b_f = bobot dan bias *forget gate*

2. Input Gate (It)

Input gate adalah komponen dalam struktur LSTM yang dimana bertugas untuk memutuskan informasi baru apa yang akan ditambahkan ke dalam cell state [29].

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

$$C_{\sim t} = \tanh(WC \cdot [h_{t-1}, x_t] + bC)$$

Rumus 2. 2 Rumus Input Gate

Keterangan:

i_t = output dari *input gate*

σ = fungsi aktivasi sigmoid

W_i, WC = Matriks bobot untuk *input gate* dan *cell candidate*

h_{t-1}, x_t = *input* pada waktu sekarang

b_i, bC = bias untuk *input gate* dan *cell candidate*

$C_{\sim t}$ = kandidat *cell state* baru

\tanh = fungsi aktivasi tanh

3. Update Cell State (Ct)

Update cell state adalah proses inti dari LSTM yang dimana bertujuan untuk memperbarui memori jangka panjang dari unit LSTM [29].

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t$$

Rumus 2. 3 Rumus Update Cell State

Keterangan:

C_t = *cell state* baru

f_t = output dari *forget gate*

C_{t-1} = *cell state* lama

i_t = output dari *input gate*

\tilde{C}_t = kandidat *cell state* baru

4. Output Gate (O_t)

Output gate adalah komponen dalam struktur LSTM yang dimana bertugas untuk mengontrol apa yang akan dijadikan output dari LSTM pada langkah waktu sekarang [30].

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

$$h_t = o_t \times \tanh(C_t)$$

Rumus 2. 4 Rumus Output Gate

Keterangan:

o_t = output dari *output gate*

b_o = bias untuk *output gate*

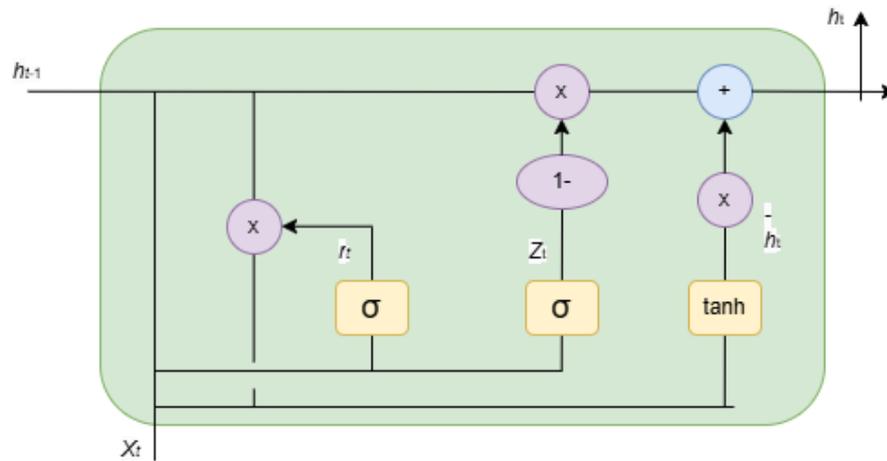
h_t = *hidden state* baru

$\tanh(C_t)$ = fungsi aktivasi tanh untuk *cell state* baru

2.3.2 Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) adalah varian lain dari LSTM yang dimana dapat didefinisikan sebagai sebuah jaringan dari tipe Recurrent Neural Network yang merupakan penyempurnaan dari arsitektur RNN tradisional. GRU bertujuan untuk menyederhanakan dan meningkatkan kemampuan memori dari jaringan RNN dengan memperkenalkan mekanisme gerbang (*gate*) yang efisien. Selain itu juga, GRU dapat membawa informasi hingga membantu mengingat input yang telah diterima oleh recurrent neural network dalam periode waktu yang cukup lama, serta mampu mengatasi permasalahan terkait prediksi secara berurutan atau time-series, seperti hilangnya informasi jangka panjang

(vanishing gradient problem), dengan struktur yang lebih ringan dibandingkan LSTM namun tetap memberikan performa yang kompetitif[31].



Gambar 2. 2 Proses GRU

Sumber: [32]

Berdasarkan Gambar 2.2, bisa dilihat bahwa struktur GRU mempunyai dua gerbang yaitu, Update Gate (Z_t) dan Reset Gate (r_t). Pada gerbang (Z_t), menentukan seberapa banyak informasi dari *hidden state* sebelumnya (h_{t-1}) akan dipertahankan dan juga seberapa banyak informasi dari *candidate hidden state* ($h_{\sim t}$) yang baru akan digunakan untuk memperbarui *hidden state* saat ini (h_t). Sedangkan untuk gerbang (r_t), menentukan seberapa banyak informasi dari *hidden state* sebelumnya (h_{t-1}) yang akan diabaikan atau di reset pada saat menghitung *candidate hidden state* ($h_{\sim t}$). Selain itu juga, setiap gerbang tersebut juga memiliki rumus itu sendiri:

1. Update Gate (Z_t)

Update gate adalah komponen utama dari GRU yang dimana bertugas untuk mengontrol berapa banyak informasi dari *hidden state* lama dan baru [33].

$$Z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z)$$

Rumus 2. 5 Rumus Update Gate

Keterangan:

Z_t = Update gate

σ = fungsi sigmoid

W_z = bobot untuk update gate

b_z = bias update gate

h_{t-1}, x_t = gabungan hidden state lama dan input sekarang.

2. Reset Gate (rt)

Reset gate adalah salah satu dari dua gerbang di dalam GRU yang dimana bertugas untuk mengatur seberapa banyak memori lama yang perlu di reset sebelum digunakan Kembali [34].

$$rt = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r)$$

Rumus 2. 6 Reset Gate

Keterangan:

rt = reset gate

σ = fungsi sigmoid

W_r = bobot untuk reset gate

B_r = bias untuk reset gate

h_{t-1}, x_t = gabungan hidden state lama dan input saat ini.

3. Kandidat Hidden State (\tilde{h}_t)

Kandidat hidden state adalah calon nilai baru dari hidden state yang dihitung sesuai dengan input saat ini dan hidden state sebelumnya [35].

$$\tilde{h}_t = \tanh(W \cdot [rt \times h_{t-1}, x_t] + b)$$

Rumus 2. 7 Rumus Kandidat Hidden State

Keterangan:

\tilde{h}_t = kandidat *hidden state* baru

\tanh = fungsi aktivasi tanh

W = bobot matriks untuk menghasilkan kandidat

b = bias kandidat

$rt \times h_{t-1}$ = hidden state lama

x_t = input saat ini

4. Update Hidden State (h_t)

Update hidden state adalah hasil akhir dari proses update dalam GRU yang dimana hidden state final setelah proses reset dan update selesai [35].

$$h_t = (1 - Z_t) \times \tilde{h}_t + Z_t \times h_{t-1}$$

Rumus 2. 8 Rumus *Update Hidden State*

Keterangan:

h_t = hidden state baru

\tilde{h}_t = kandidat hidden state baru

h_{t-1} = hidden state lama

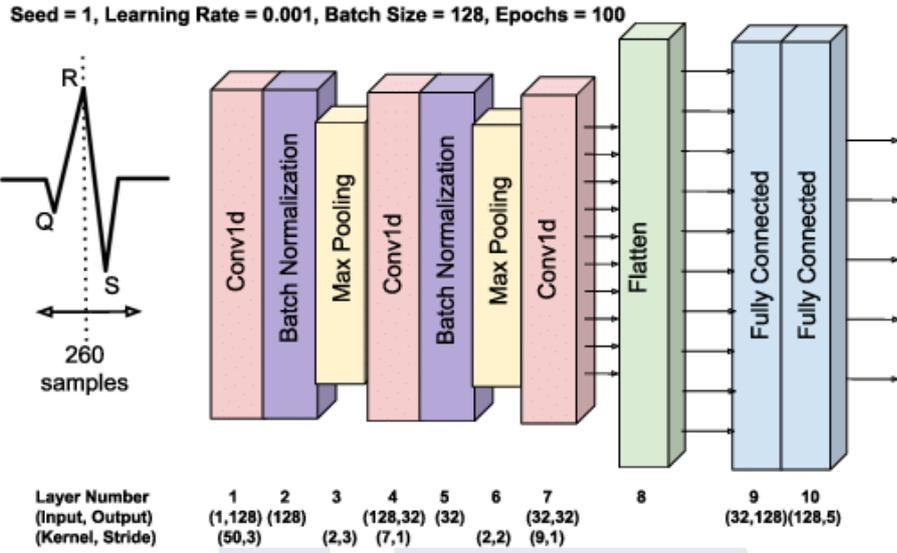
Z_t = update gate

$1-Z_t$ = kontrol berapa banyak kandidat hidden state baru yang dipakai.

2.3.3 1-Dimensional Convolutional Neural Network (1D-CNN)

1-Dimensional Convolutional Neural Network (1D-CNN) adalah arsitektur jaringan saraf dalam pembelajaran mendalam yang dibuat untuk menangani data berurutan satu dimensi, seperti sinyal, teks, atau deret waktu. Berbeda dari CNN dua dimensi yang umum digunakan untuk citra, 1D-CNN mengaplikasikan filter konvolusi sepanjang satu dimensi untuk mengekstraksi fitur penting dari input. Proses ini memungkinkan jaringan mengenali pola lokal dalam urutan data, seperti tren harga dalam data saham. Dengan lapisan konvolusi, aktivasi, dan pooling, 1D-CNN dapat secara efisien menangani prediksi dan klasifikasi data berurutan dengan jumlah parameter yang relatif sedikit [36].

U N I V E R S I T A S
M U L T I M E D I A
N U S A N T A R A



Gambar 2. 3 TensorFlow 1D-CNN

Sumber: [37]

Berdasarkan gambar 2.3, bisa dilihat bahwa model pada 1D-CNN dibuat untuk memproses data deret waktu satu dimensi. Model tersebut terdiri dari beberapa lapisan yang dipakai untuk ekstraksi fitur dan klasifikasi seperti, Input Layer (Layer 0-10) yang dimana menerima input berupa deret waktu 1 dimensi dengan panjang sampel seperti yang ada digambar yaitu 260 sampel dan bentuk inputnya juga menunjukkan ukuran batch yang fleksibel. Umumnya, CNN berjalan dengan cara mengekstraksi fitur-fitur hierarkis dari input melalui konvolusi dan juga pooling. Berikut ini adalah beberapa lapisannya:

1. Konvolusi (Conv1D): Lapisan konvolusi menggunakan sejumlah filter (kernel) kecil untuk memindai input. Setiap filter belajar untuk mendeteksi pola spesifik dalam data. Dalam 1D, filter bergerak sepanjang dimensi waktu[37].
2. Batch Normalization: Menstabilkan proses pelatihan[37].
3. Max Pooling: Mengurangi dimensi spasial dan membuat model lebih invarian terhadap pergeseran[37].
4. Flatten: Mengubah representasi fitur multi-dimensi menjadi vektor untuk diumpankan ke lapisan fully connected[37].

5. Fully Connected (Dense): Lapisan fully connected menggunakan bobot yang dipelajari untuk menggabungkan fitur-fitur yang diekstraksi untuk membuat prediksi akhir (dalam kasus ini, klasifikasi EKG) [37].

2.4 Teori Metrik Evaluasi

2.4.1 Root Mean Squared Error (RMSE)

Root Mean Square Error (RMSE) merupakan salah satu metrik evaluasi yang paling sering digunakan untuk menilai tingkat akurasi model prediksi, khususnya pada model regresi. RMSE menghitung rata-rata kesalahan antara nilai aktual dan nilai yang diprediksi oleh model, dengan terlebih dahulu mengkuadratkan selisihnya dan kemudian diakar. Karena menggunakan pendekatan kuadrat, RMSE memberikan penekanan lebih besar pada kesalahan yang besar, sehingga metrik ini cukup peka terhadap outlier atau nilai prediksi yang sangat melenceng[38].

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{Y}_i - Y_i)^2}{n}}$$

Rumus 2. 9 Rumus RMSE

Keterangan:

n = jumlah total data

Y_i = nilai sebenarnya (aktual) untuk data ke- i

\hat{Y}_i = nilai perkiraan (prediksi) untuk data ke- i

2.4.2 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) adalah metrik evaluasi yang mengukur keakuratan model prediktif dengan menghitung perbedaan rata-rata absolut antara nilai aktual dan nilai prediksi. Dalam kerangka pembelajaran mesin, MAE berfungsi sebagai ukuran kinerja model regresi atau prediksi numerik. MAE memberikan indikasi intuitif dan langsung tentang seberapa jauh prediksi model menyimpang dari nilai sebenarnya, menjadikannya salah satu metrik termudah untuk ditafsirkan[38].

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|$$

Rumus 2. 10 Rumus MAE

Keterangan:

n = jumlah total data

Y_i = nilai sebenarnya (aktual) untuk data ke- i

\hat{Y}_i = nilai perkiraan (prediksi) untuk data ke- i

2.4.3 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan metrik evaluasi yang dipakai untuk menilai tingkat akurasi model prediktif dengan cara menghitung rata-rata persentase dari selisih absolut antara nilai aktual dan nilai prediksi. Karena hasilnya dinyatakan dalam bentuk persen, MAPE memudahkan interpretasi kinerja model secara relatif. Metrik ini memiliki manfaat ketika fokus analisis lebih mengutamakan perbandingan proporsional daripada besarnya kesalahan secara absolut[39].

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100$$

Rumus 2. 11 Rumus MAPE

Keterangan:

N = banyak data

A_i = nilai sebenarnya untuk data ke- i

F_i = nilai perkiraan untuk data ke- i

2.4.5 R-Squared (R²)

R-Squared (R²) adalah metrik statistik yang digunakan untuk mengukur seberapa baik model regresi menjelaskan variabilitas data target. Nilai R² berada antara 0 dan 1, di mana nilai mendekati 1 menunjukkan bahwa model mampu

menjelaskan sebagian besar variabilitas data, sedangkan nilai mendekati 0 menunjukkan kemampuan prediksi yang lemah[40].

$$R^2 = 1 - \frac{\sum(y_i - y_c)^2}{\sum(y_i - y_r)^2}$$

Rumus 2. 12 Rumus R^2

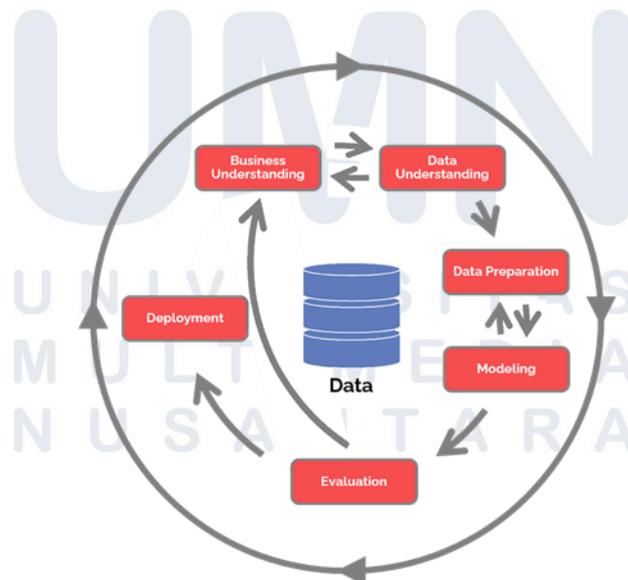
y_i = data ke – i

y_c = data estimasi dari persamaan regresi

y_r = data rata – rata

2.5 CRISP-DM

Cross-Industry Standard Process for Data Mining atau singkatnya CRISP-DM merupakan standar metodologi yang dimana dikembangkan sejak tahun 1996. Metode ini dibuat supaya dapat membantu proses analisis dalam berbagai industri sebagai strategi dalam menyelesaikan permasalahan bisnis atau penelitian. Data yang digunakan dalam metode ini tidak harus memiliki karakteristik khusus, karena akan diproses dan dianalisis melalui tahapan-tahapan tertentu yang telah ditetapkan dalam metodologi ini [41]. Terdapat tahap-tahap CRISP-DM dalam memproses data sebagai berikut:



Gambar 2. 4 Tahapan CRISP-DM

Sumber: [42]

Berdasarkan gambar 2.4, merupakan 6 tahapan dari CRISP-DM yang dimana akan dilakukan oleh peneliti, dimulai dari bussines understanding, data understanding, data preparation, modeling, evaluation, dan deployment.

2.6 Teori tentang tools/software yang digunakan

2.6.1 Python

Python adalah bahasa pemrograman yang memiliki kemampuan untuk mengeksekusi instruksi multiguna secara langsung (interpretatif) melalui metode orientasi objek. Selain itu, python sendiri juga menggunakan semantik dinamis yang dimana digunakan untuk meningkatkan keterbacaan syntax. Menurut beberapa orang Python dianggap sebagai bahasa yang mampu, menggabungkan kemampuan serta sintaksis kode yang sangat mudah dipahami, dan memiliki berbagai fitur pustaka standar yang luas dan komprehensif. Python dirancang untuk menjadi mudah dipelajari dan dipahami, meskipun itu tergolong bahasa pemrograman dengan level tinggi. Python memiliki fitur yang menarik, jadi layak untuk dipelajari. Pertama dan terpenting, Python memiliki tata bahasa dan script yang sangat mudah dipelajari. Selain itu, Python memiliki sistem Penerapan Algoritma Machine Learning untuk Memprediksi harga saham [43].

2.6.2 Google Colab

Google Colab, atau Google Colaboratory, adalah platform cloud milik Google yang dirancang untuk mempermudah pengguna dalam menulis, mengeksekusi, serta membagikan kode Python secara daring. Platform ini banyak dimanfaatkan oleh pengembang, peneliti, hingga pelajar karena menyediakan lingkungan komputasi yang praktis tanpa perlu menginstal software tambahan di perangkat lokal. Google Colab memungkinkan akses langsung ke notebook Jupyter melalui browser, sehingga pengguna dapat menggunakannya kapan saja dan di mana saja selama terhubung ke internet. Salah satu kelebihan utamanya adalah dukungan terhadap GPU (Graphics Processing Unit) dan TPU (Tensor Processing Unit) secara gratis, yang sangat

membantu dalam menyelesaikan tugas-tugas komputasi berat seperti pelatihan model machine learning atau analisis data berskala besar. Colab juga terhubung dengan Google Drive, sehingga pengguna bisa dengan mudah menyimpan serta berbagi notebook. Dengan fitur kolaborasi yang menyerupai Google Docs, beberapa pengguna dapat bekerja secara bersamaan dalam satu notebook, menjadikannya pilihan ideal untuk proyek kolaboratif maupun pembelajaran kelompok [44].



UMMN

UNIVERSITAS
MULTIMEDIA
NUSANTARA