

BAB II

LANDASAN TEORI

2.1 Penelitian Terkait

Penelitian terdahulu atau yang terkait dilakukan dengan pencarian kata kunci; *Stock prediction*, *Deep learning*, Bank Digital, *Long Short-Term Memory (LSTM)* dan *Extended Long Short-Term Memory (xLSTM)* dengan rentang waktu di tahun 2020 hingga tahun 2025, yang dimana hasil temuan dari penelitian-penelitian terdahulu dilampirkan pada tabel 2.1.

Tabel 2.1 Penelitian terdahulu

Judul Artikel	Penulis	Tahun	Algoritma	Hasil
Analysis of Financial Time Series Forecasting using Deep Learning Model [3]	Raghavendra Kumar, Pardeep Kumar, Yugal Kumar	2021	<i>Stacked Long Short-Term Memory (LSTM)</i> , <i>Moving Average (MA)</i> , dan XGBoost	<i>stacked Long Short-Term Memory (LSTM)</i> dan membandingkannya dengan model <i>Moving Average (MA)</i> dan XGBoost. Hasilnya menunjukkan bahwa model <i>stacked LSTM</i> memiliki kinerja terbaik di antara ketiganya. Secara spesifik, model LSTM mencapai nilai <i>Root Mean Square Error (RMSE)</i> 7.834 dan <i>Mean Absolute Percentage Error (MAPE)</i> 0.80, yang secara signifikan lebih unggul dibandingkan dengan XGBoost RMSE 8.807 dan MAPE 1.01 lalu <i>Moving Average</i> RMSE 10.094 dan MAPE 1.13.
LSTM ALGORITHM ANALYSIS OF	Mutmainah, Umi Marfuah,	2022	Long Short-term Memory (LSTM) dan	Algoritma <i>Long-Short Term Memory (LSTM)</i> dapat digunakan dalam memprediksi

Judul Artikel	Penulis	Tahun	Algoritma	Hasil
BANKING SECTOR STOCK PRICE PREDICTIONS [2]	Rina Nopianti, Andreas Tri Panudju		Recurring Neural Network (RNN)	harga saham secara akurat di sektor perbankan. Penelitian ini menggunakan data dari bank-bank BUMN dan menerapkan teknik <i>preprocessing</i> , pemodelan data LSTM, pelatihan, pengujian, dan visualisasi. Setelah itu berbagai model optimasi diuji, termasuk Adam, RMSProp dan SGD, dengan <i>epoch</i> yang berbeda-beda (25, 50, 75, 100). Temuan menunjukkan bahwa model optimasi Adam dengan nilai <i>epoch</i> yang lebih tinggi menghasilkan tingkat kerugian yang lebih rendah dan akurasi yang lebih tinggi dalam prediksi harga saham mencapai hingga 95%. Secara keseluruhan, penggunaan algoritma LSTM dengan model optimasi Adam menunjukkan hasil yang menjanjikan dalam memprediksi harga saham pada sektor perbankan.
Forex market forecasting with two-layer stacked Long Short-Term Memory neural	Michael Ayitey Junior, Peter Appiahene, Peter Appiahene	2022	Long Short- term Memory (LSTM), two- layer stacked LSTM	Pengembangan <i>framework</i> untuk memprediksi Forex menggunakan eksponen Hurst, <i>two-layer stacked LSTM architecture</i> dan analisis korelasi (<i>correlation</i>).

Judul Artikel	Penulis	Tahun	Algoritma	Hasil
network (LSTM) and correlation analysis [6]				<i>Framework</i> yang diusulkan lebih unggul dari model-model lain dalam hal <i>Mean Square Error</i> , <i>Root Mean Square Error</i> , dan <i>Mean Absolute Error</i> . Pada penelitian ini dilakukan analisis korelasi (<i>correlation</i>) antara pasangan mata uang yang berbeda dan menemukan bahwa adanya korelasi tinggi antara pasangan mata uang tersebut yang memungkinkan dapat mempunyai pengaruh signifikan antara satu sama lain. Secara keseluruhan, penelitian ini menunjukkan hasil yang menjanjikan dalam menggunakan eksponen Hurst dan <i>two-layer stacked LSTM</i> dalam memprediksi Forex (<i>Foreign Exchange</i>).
Stock price prediction with long short-term memory [7]	Z. D. Aehir, E. K�yl�c, S. Akleylek, M. D�ng�l, and B. Cokun	2020	Long Short-term Memory (LSTM), K-Nearest Neighbour (KNN) dan Coefficient of Determination (R ²)	Artikel ini menunjukkan bahwa model LSTM lebih unggul dibandingkan dengan model KNN dalam hal metrik evaluasi. Model LSTM memiliki MAE, RMSE, dan MAPE yang lebih rendah, serta R ² yang lebih tinggi, yang mengindikasikan kinerja yang lebih baik. Parameter yang optimal untuk model LSTM adalah learning rate

Judul Artikel	Penulis	Tahun	Algoritma	Hasil
				0.005, jumlah epoch 30, ukuran batch 16, dan jumlah <i>hidden layer</i> 32. Model LSTM memberikan prediksi harga saham yang lebih akurat dibandingkan dengan model KNN. Visualisasi data prediksi juga menunjukkan bahwa model LSTM sangat sesuai dengan data aktual, sedangkan model KNN memiliki prediksi yang kasar dan juga tidak akurat. Secara keseluruhan, model LSTM menunjukkan kinerja dan akurasi yang lebih baik dalam memprediksi harga saham atau <i>stock market</i> daripada model KNN.
An Evaluation of Deep Learning Models for Stock Market Trend Prediction[4]	Gonzalo López Gil, Paul Duhamel-Seblin, Andrew McCarren	2024	xLSTM-TS, TCN, N-BEATS, TFT, N-HiTS, TiDE, Wavelet Denoising	Pada penelitian ini model xLSTM-TS terbukti unggul dalam memprediksi arah tren pasar saham S&P 500 dan EWZ (Brazil ETF). Dengan <i>preprocessing wavelet denoising</i> , xLSTM-TS mencapai akurasi hingga 72.87% dan F1 <i>score</i> 73.16% pada data harian EWZ, serta nilai ukuran RMSE dan MAE paling rendah di antara model lain. Kelebihannya mencakup kestabilan dalam prediksi jangka pendek dan panjang

Judul Artikel	Penulis	Tahun	Algoritma	Hasil
				pada data volatil dan kompleks.
xLSTMTIME: Long Term Time Series Forecasting with xLSTM [8]	Musleh Alharthi, Ausif Mahmood	2024	xLSTMTIME (gabungan antara sLSTM dengan mLSTM, dan sequence decomposition & RevIN)	xLSTMTIME menunjukkan performa yang unggul dalam hasil <i>benchmark multivariate long-term time series forecasting</i> , yang diukur dengan metrik MSE (<i>Mean Squared Error</i>) dan MAE (<i>Mean Absolute Error</i>). Model ini terbukti mengungguli model populer seperti Informer, Autoformer, FEDformer, PatchTST, dan DLinear pada sebagian besar dari 12 dataset nyata (cuaca, lalu lintas, listrik, ILI, nilai tukar, dan PEMS). Dibandingkan dengan DLinear, peningkatan performa yang paling signifikan terlihat pada dataset Illness (ILI), di mana xLSTMTIME mencapai peningkatan akurasi sebesar 22.62%. Selain itu, pada dataset PeMS03, xLSTMTIME juga menunjukkan hasil 9% lebih baik pada MSE dan 5% lebih baik pada MAE dibandingkan model canggih lainnya. Model ini efektif untuk prediksi jangka panjang (horizon $T=720$), efisien

Judul Artikel	Penulis	Tahun	Algoritma	Hasil
				karena memiliki kompleksitas waktu linear, dan stabil terhadap pergeseran distribusi data
Advanced Stock Price Prediction with xLSTM-Based Models: Improving Long-Term Forecasting [5]	Xiaojing Fan, Chunliang Tao, Jianyu Zhao	2024	xLSTM dan LSTM (perbandingan), multihorizon forecast	Hasil dari penelitian ini adalah membandingkan xLSTM dengan LSTM yang dimana kedua metode tersebut di uji atau digunakan pada data saham AAPL, JNJ, dan NKE untuk horizon t+1 hingga t+15. xLSTM secara konsisten memberikan hasil yang lebih baik dari LSTM dengan RMSE lebih rendah dan R ² lebih tinggi, terutama dalam prediksi jangka panjang. Rata-rata RMSE menurun dari 9.99 ke 8.60 dan R ² meningkat dari 0.39 ke 0.48 untuk t+15. Hasil ini menunjukkan bahwa metode xLSTM lebih andal dalam menangani ketergantungan jangka panjang dan kondisi pasar yang fluktuatif.
PENGARUH MOBILE BANKING TERHADAP PROFITABILITAS BANK DI BURSA EFEK INDONESIA [1].	Nur Imamah, Dinda Ayu Safira	2021	Random Effect Model (REM), Generalized Least Square (GLS)	Studi ini menunjukkan bahwa <i>mobile banking</i> memiliki pengaruh yang positif, tetapi tidak signifikan secara statistik terhadap (ROA), (ROE) dan juga (NPM) bank, Bursa Efek Indonesia. Ini menunjukkan <i>mobile banking</i> dapat

Judul Artikel	Penulis	Tahun	Algoritma	Hasil
				meningkatkan profitabilitas pada bank dengan cara meningkatkan inovasi digital. Nilai minimum ROA, ROE, dan NPM masing-masing adalah 1.410000, 43.37000, 14.4526, dan 9.608697.
Prediksi Tren Pergerakan Harga Saham PT Bank Central Asia Tbk, Dengan Menggunakan Algoritma Long Shot Term Memory (LSTM) [9]	M Nurul Wathani, Kusrini, Kusnawi	2023	Long Short-term Memory (LSTM)	Pada pengembangan model dengan menggunakan algoritma LSTM untuk memprediksi harga saham PT Bank Central Asia Tbk, Model tersebut dilatih dan diuji dengan menggunakan data historis, dan ditentukan kombinasi parameter yang terbaik. Model menunjukkan akurasi yang baik dalam memprediksi harga saham penutupan, dengan <i>Mean Absolute Error</i> (MAE) sebesar 96,924, <i>mean squared error</i> (MSE) sebesar 16185,226, dan <i>root mean squared error</i> (RMSE) sebesar 127,221. Model ini dapat dikatakan sebagai model yang optimal untuk memprediksi harga saham dalam sektor perbankan bursa efek Indonesia.
Prediksi Tren Harga Saham Menggunakan Metode Long	Sulthan Ali Pasha	2023	Long Short-term Memory (LSTM) dengan 4	Pada penelitian ini membandingkan 4 model LSTM (dengan kompleksitas yang berbeda) dengan tujuan

Judul Artikel	Penulis	Tahun	Algoritma	Hasil
Short-Term Memory [10]			varian model: 1-4 hidden layer	memprediksi harga saham 3 perusahaan bursa efek di Indonesia (INCO, BKSL, TPIA) dengan tingkat volatilitas berbeda. Model 2 (1 <i>hidden layer</i> , 50 unit) memberikan performa yang terbaik pada semua perusahaan, berdasarkan metrik RMSE dan MAE. Model yang lebih kompleks (Model 3 dan 4) tidak selalu memberikan hasil lebih baik. Pengujian dilakukan dengan menggunakan data dari Yahoo <i>Finance</i> periode 2012-2022.

Dari berbagai penelitian yang telah dirangkum pada tabel 2.1, penggunaan algoritma *deep learning* untuk prediksi finansial menjadi signifikan. Secara kolektif, penelitian-penelitian tersebut menunjukkan bahwa algoritma Long Short-Term Memory (LSTM) dan variannya secara konsisten terbukti memberikan performa yang cukup baik. Studi oleh Kumar et al.[3] dan Aehir et al.[7], menunjukkan bahwa LSTM lebih unggul dibandingkan model tradisional seperti *Moving Average* dan model *machine learning* seperti KNN. Penerapan model tersebut juga terbukti efektif pada sektor perbankan di Indonesia, seperti yang ditunjukkan pada prediksi saham BUMN oleh Mutmainah et al.[2], dan saham PT Bank Central Asia Tbk oleh Wathani et al.[9], arsitektur *stacked LSTM* juga menunjukkan performa yang baik dalam prediksi pasar Forex, yang mendukung penggunaan model *stack* untuk menangkap pola yang lebih kompleks.

Beberapa penelitian yang menjadi sorotan utama karena mulai mengeksplorasi dan membuktikan keunggulan *Extended Long Short-Term Memory* (xLSTM). Pada penelitian yang dilakukan oleh Gil et al.[4], menunjukkan model xLSTM-TS

terbukti unggul dengan akurasi mencapai 72.87% dalam memprediksi tren pasar saham S&P 500 yang sangat kompleks. Studi yang dilakukan oleh Alharthi & Mahmood[8] juga memperkuat temuan ini dengan menunjukkan bahwa xLSTMTIME (salah satu varian xLSTM) mengungguli model-model lainnya di berbagai dataset *time-series*, pada weather dataset, model ini menunjukkan peningkatan performa sebesar 18.18% dalam prediksi 96 langkah ke depan, dan pada Illness (ILI) dataset, peningkatannya bahkan mencapai 22.62% dibandingkan dengan model DLinear. Yang paling relevan adalah penelitian yang dilakukan oleh Fan et al.[5], yang secara langsung membandingkan performa xLSTM dengan LSTM pada saham-saham besar AS dan menyimpulkan bahwa xLSTM secara konsisten dapat memberikan RMSE lebih rendah dan R^2 lebih tinggi, terutama untuk prediksi jangka panjang. Temuan-temuan ini menjadi alasan utama mengapa perbandingan xLSTM dan LSTM perlu dilakukan lebih lanjut.

Berdasarkan tinjauan keseluruhan tersebut, penelitian ini mengadaptasi beberapa fondasi utama dari studi-studi sebelumnya. Penelitian ini mengadopsi metodologi perbandingan langsung antara algoritma xLSTM dan LSTM sebagaimana yang dilakukan oleh Fan et al.[5], dengan menggunakan metrik evaluasi standar seperti RMSE dan MAPE yang umum digunakan di hampir semua penelitian yang dilakukan sebelumnya. Pendekatan untuk fokus pada sektor perbankan Indonesia juga dilakukan pada penelitian Mutmainah et al.[2], dan Wathani et al.[9], yang telah membuktikan relevansi model LSTM untuk pasar lokal. Pada penelitian ini hanya digunakan standar LSTM saja dikarenakan *stacked* LSTM pada penelitian terdahulu berfokus pada pasar *crypto* (Forex) sedangkan penelitian ini berfokus pada prediksi saham bank digital. Adapun perbedaan dan kebaruan dari penelitian ini terletak pada konteks objek penelitian yang spesifik dan belum dieksplorasi. Jika penelitian Fan et al.[5], berfokus pada saham teknologi besar di pasar AS, pada penelitian ini diterapkan perbandingan tersebut pada sektor perbankan digital di Indonesia.

Sektor perbankan digital memiliki karakteristik unik, dengan tingkat pertumbuhan yang sangat tinggi dan volatilitas pasar yang unik, yang berbeda dari sektor perbankan konvensional maupun pasar saham global. Dengan demikian, penelitian ini tidak hanya mereplikasi metode, tetapi juga melakukan analisis untuk menguji apakah keunggulan performa xLSTM yang ditemukan di pasar internasional juga berlaku di pasar *emerging* yang spesifik seperti Indonesia. Kontribusi utamanya adalah memberikan bukti yang didasarkan pada penelitian dan pengetahuan yang terdahulu mengenai algoritma prediksi yang paling sesuai untuk aset saham bank digital Indonesia, dalam bentuk wawasan yang bernilai praktis bagi investor dan analisis di pasar modal lokal.

Selain fokus kepada analisis secara teknikal, dilakukan juga pendekatan yang menggabungkan analisis pola historis, pemodelan prediktif dan visualisasi dari hasil yang mampu memberikan gambaran atau *insight* yang lebih komprehensif bagi para investor atau pengambil keputusan. Visualisasi antara nilai aktual dan nilai prediksi, membantu dalam melakukan identifikasi tren, deviasi dan tingkat performa pada model dalam menangkap pola pergerakan harga. Temuan ini menegaskan bahwa keberhasilan suatu model analisis prediktif sangatlah bergantung pada pemilihan metode yang tepat, kualitas data yang digunakan dan diperlukan juga penyesuaian terhadap pemodelan yang dianalisis.

2.2 Teori Penelitian

2.2.1 Deep Learning

Deep Learning adalah suatu metode atau teknik yang terdapat didalam *machine learning*, yang menggunakan *neural network* dengan banyak *layer* yang umumnya lebih dari 3-*layer* dalam melakukan memproses dan analisa pada sebuah data. *Deep learning* telah menunjukkan potensi besar dalam mengelola set data yang besar dan rumit, terutama dalam hal jaringan syaraf tiruan multi-layer[11]. *Deep learning* memungkinkan *machine learning* dalam mempelajari representasi data secara hierarkis dan otomatis dari fitur yang sederhana hingga ke fitur yang kompleks.

2.2.2 Bank Digital

Bank Digital dikenal juga sebagai bank elektronik atau *bank online* yang merupakan otomatisasi dari layanan perbankan konvensional. Hal tersebut menghadirkan kemungkinan bagi para nasabah bank dalam mengakses produk dan layanan perbankan melalui platform elektronik atau *online*, yang berarti nasabah dapat mengelola keuangan mereka tanpa harus pergi ke cabang fisik atau gedung kantor layanan[12]. Bank Digital mengandalkan teknologi digital dan komunikasi *online* untuk memberikan layanan perbankan, hal ini berbeda secara signifikan dari bank konvensional yang tetap mengoperasikan lokasi gedung layanan fisik atau lokasi kantor dari bank tersebut.

2.2.3 Bank Conventional

Bank Conventional adalah suatu lembaga keuangan yang memberikan berbagai layanan kepada para customer atau pengguna, termasuk rekening simpanan dan pinjaman. Pada umumnya mereka diatur atau dikontrol oleh lembaga pemerintahan seperti OJK (Otoritas Jasa Keuangan) dan beroperasi berdasarkan kerangka hukum dan peraturan yang bersangkutan dengan perusahaan yang mengurus tentang keuangan.

2.2.4 Time-Series

Data time series merupakan serangkaian data yang dikumpulkan dan dicatat dalam interval waktu yang teratur. [13]Data ini umumnya digunakan didalam berbagai bidang, seperti; keuangan, pemrosesan sinyal, ekonomi, dan meteorologi. *Data time series* juga dapat digunakan untuk menganalisis tren, pola musiman, sifat, siklus, dan fluktuasi (naik atau turunnya harga) yang acak dari variabel yang diamati seiring waktu.

2.2.5 Investasi

Investasi merupakan penanaman modal yang biasanya dilakukan dalam jangka waktu yang panjang, untuk pengadaan aktiva (Aset) lengkap atau pembelian saham dan surat berharga, dengan tujuan untuk memperoleh keuntungan[14]. Hal ini merupakan tindakan atau proses mengalokasikan sumber daya, seperti uang, waktu,

atau tenaga kerja, ke dalam suatu aset atau proyek dengan harapan untuk mendapatkan keuntungan maupun penghasilan yang lebih besar dikemudian harinya atau dimasa yang akan mendatang[15].

Tujuan dari investasi adalah untuk mengembangkan atau melindungi nilai aset, atau mencapai tujuan keuangan jangka panjang, seperti pensiun, pendidikan anak, atau pertumbuhan kekayaan[14].

2.2.6 Saham

Saham merupakan sebuah bukti kepemilikan suatu nilai dari sebuah perusahaan atau bukti penyertaan modal yang ditanam ataupun dipinjamkan untuk suatu perusahaan. Para pemilik saham juga memiliki hak dalam mendapatkan *dividend* yang sesuai dengan jumlah lot saham yang dimiliki oleh para pemilik saham pada perusahaan tersebut [16].

2.2.7 Pemegang Saham

Pemegang saham adalah seorang individu atau entitas yang memiliki saham pada suatu perusahaan. Mereka memiliki hak didalam perusahaan, termasuk hak untuk ikut serta dalam pemilihan direksi atau direktur, menerima dividen (pembagian keuntungan perusahaan kepada para pemegang saham) [16], dan mendapatkan manfaat dari kenaikan nilai saham jika mengalami kenaikan harga pada pasar saham.

U M N
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

2.3 Framework dan Algoritma Penelitian

2.3.1 Framework

Dalam penentuan metodologi, diperlukan analisis untuk mendapatkan jenis-jenis *framework* yang sesuai didalam penelitian ini dan *framework* yang paling bagus untuk melakukan pemodelan pada penelitian ini, Berikut ini merupakan beberapa perbandingan *framework* yang akan dibandingkan, sebagai berikut:

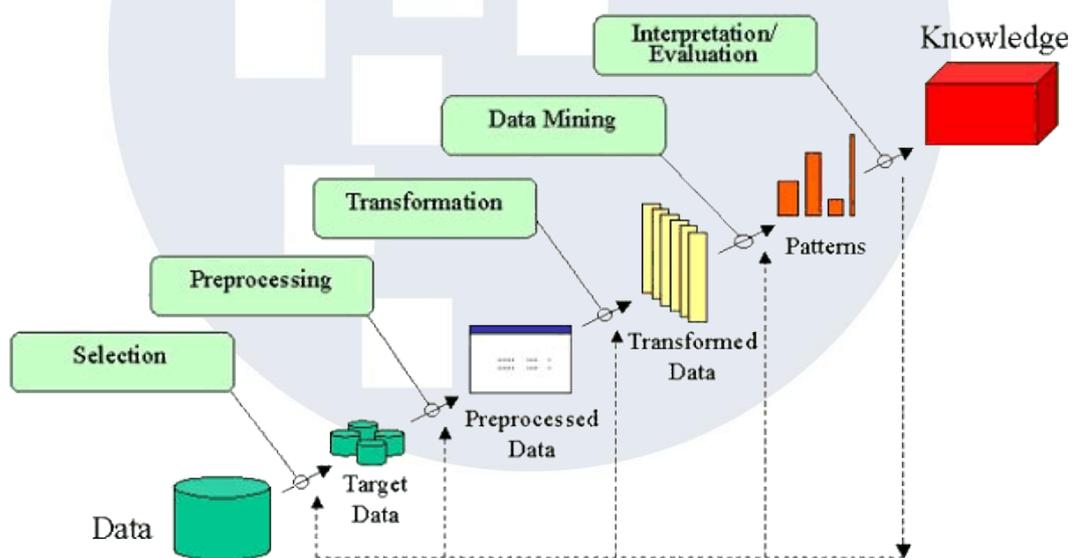
Tabel 2.2 Perbandingan Framework

Indikator	CRISP-DM	SEMMA	KDD
Pengertian	CRISP-DM <i>framework</i> (<i>Cross-Industry Standard Process for Data Mining</i>) merupakan suatu <i>framework</i> yang memiliki fungsi untuk proses data mining sekaligus juga analisis data.	SEMMA (<i>Sample, Explore, Modify, Model, Assess</i>) merupakan suatu metode pada data mining yang dikembangkan oleh SAS Institute.	KDD (<i>Knowledge Discovery in Database</i>) merupakan sebuah proses untuk mengekstrak informasi yang berharga, implisit dan tidak dikenal dari sekumpulan data pada data penelitian.
Kelebihan	<ol style="list-style-type: none"> 1. Bersifat fleksibel dan dapat disesuaikan dengan berbagai jenis penelitian sekaligus juga alat <i>data mining</i>. 2. Merupakan metode yang paling populer dan juga banyak digunakan didalam projek <i>data mining</i>, sehingga memiliki banyaknya referensi ataupun contoh penelitian yang terdahulu. 3. Metode yang bersifat umum dan tidak eksklusif yang dimana metode ini dapat digunakan untuk menyelesaikan berbagai macam masalah dengan menggunakan <i>data mining</i> yang tepat. 	<ol style="list-style-type: none"> 1. Metode ini dapat memangkas waktu pengerjaan dengan lebih cepat, seperti; pada tahap kedua dan ketiga dapat disatukan ataupun tahap kelima sampai tahap ketujuh juga dapat disatukan, sehingga dapat lebih mempercepat pengerjaan. 2. Metode ini dapat digunakan dengan mudah sekaligus juga mudah untuk dipahami proses yang terkait didalam proses pemeliharaan projek pada <i>data mining</i>. 	<ol style="list-style-type: none"> 1. Metode ini dapat menghasilkan pengetahuan yang bermakna dari kata yang besar, kompleks sekaligus beragam. 2. KDD dapat mendukung dalam pengambilan keputusan yang lebih baik dan cepat berdasarkan data yang <i>valid</i> dan akurat. 3. Metode ini dapat mengungkap pola, hubungan dan tren yang dimana tidak terlihat secara manual atau dengan cara metode tradisional. 4. KDD dapat meningkatkan efisiensi dan produktivitas dalam melakukan pengelolaan data dan informasi.
Kekurangan	1. Metode ini tidak mempertimbangkan	1. Metode ini tidak mempertimbangkan	1. KDD membutuhkan waktu,

Indikator	CRISP-DM	SEMMA	KDD
	<p>dalam beberapa aspek, yaitu; etika, hukum dan privasi dalam penggunaan <i>data mining</i> yang dimana hal tersebut dapat menimbulkan masalah moral dan legal.</p> <p>2. Metode ini tidak memiliki tahapan untuk melakukan validasi sekaligus juga verifikasi pada model secara eksternal, sehingga dapat menyebabkan model tersebut menjadi tidak akurat dan tidak valid.</p> <p>3. Metode ini tidak memiliki mekanisme untuk melakukan <i>monitoring</i> atau memantau dan juga memperbaiki <i>model</i> yang telah dibuat, sehingga dapat menyebabkan adanya ketinggalan zaman dan juga tidak relevan.</p>	<p>beberapa aspek, seperti; etika, privasi dan hukum didalam penggunaan <i>data mining</i>, yang dimana hal tersebut dapat menimbulkan masalah mengenai moral dan juga legalitas.</p> <p>2. Metode ini tidak memberikan pedoman yang jelas dan spesifik terhadap bagaimana melakukan setiap tahapan, melainkan metode ini hanya memberikan gambaran umum yang dapat berbeda-beda, tergantung dengan konteks dan alat yang digunakan.</p>	<p>biaya dan juga sumber daya yang cukup besar untuk melakukan proses.</p> <p>2. Metode ini membutuhkan keahlian dan pengetahuan yang cukup tinggi dalam memilih, menerapkan dan mengevaluasi metode dan teknik yang sesuai dengan data dan juga tujuan dari penelitian.</p> <p>3. Metode ini dapat menghasilkan hasil yang tidak relevan atau tidak <i>valid</i>, jika data, metode ataupun teknik yang digunakan tidak sesuai ataupun juga tidak berkualitas.</p>
Proses	<i>Iterative</i>	<i>Sequential</i>	<i>Iterative</i>
Fokus Utama	Berfokus pada pemahaman tujuan sekaligus pada kebutuhan bisnis	Berfokus pada eksplorasi dan memodifikasi data untuk menghasilkan model prediktif.	Berfokus pada keseluruhan proses yang ada didalam <i>knowledge discovery</i> yang ditujukan untuk bidang bisnis.
Tahap Framework	<ol style="list-style-type: none"> 1. <i>Business understanding</i> 2. <i>Data understanding</i> 3. <i>Data preparation</i> 4. <i>Modeling</i> 5. <i>Evaluation</i> 6. <i>Deployment</i> 	<ol style="list-style-type: none"> 1. <i>Sample</i> 2. <i>Explore</i> 3. <i>Modify</i> 4. <i>Model</i> 5. <i>Assess</i> 	<ol style="list-style-type: none"> 1. <i>Selection</i> 2. <i>Preprocessing</i> 3. <i>Transformation</i> 4. <i>Data Mining</i> 5. <i>Interpretation/ Evaluation</i> 6. <i>Knowledge</i>

Berdasarkan perbandingan antara beberapa *framework* pada tabel 2.2, setiap *framework* memiliki tahapan dan tujuan implementasi yang berbeda-beda. Dari hasil perbandingan tersebut, dapat disimpulkan, bahan metode KDD dapat diterapkan sebagai kerangka kerja atau *framework* yang tepat ke dalam penelitian

ini, dikarenakan metode KDD mampu menerjemahkan permasalahan dan tujuan penelitian ke dalam proses analisis data secara sistematis dan terstruktur. Metode KDD terdiri dari beberapa tahapan inti, yaitu seleksi data, pembersihan data, transformasi data, *data mining*, evaluasi pola dan representasi pengetahuan. Tahapan ini sejalan dengan kebutuhan penelitian yang tidak hanya bertujuan menerapkan model prediktif, tetapi sekaligus juga menggali pengetahuan dari data historis dengan tujuan untuk mendukung pengambilan keputusan.



Gambar 2.1 Tahapan KDD

(Sumber: *KDD Process in Data Science: A Beginner's Guide* | by Shawn Chumbar | Medium)

Knowledge Discovery in Database (KDD) adalah proses sistematis untuk melakukan ekstraksi pengetahuan yang berguna dan dapat dipahami. KDD muncul dari kebutuhan untuk menganalisis data yang besar[17]. KDD merupakan proses yang tidak sepele yang bertujuan mengidentifikasi pola-pola yang valid, KDD mencakup beberapa rangkaian tahapan yang dimulai dari pemilihan data hingga interpretasi dari hasil, yang memiliki tujuan akhir untuk menghasilkan informasi yang dapat mendukung dalam pengambilan keputusan, berikut ini merupakan proses tahapan-tahapan utama pada metode KDD:

1. **Memilah dan Melakukan Seleksi Data (*Data Selection*):** Pada tahap ini, dilakukan proses pemilihan data yang relevan dari berbagai sumber seperti; data operasional, data transaksi, data eksternal dan data historis untuk dilakukan analisis dan evaluasi lebih lanjut. Dengan tujuan untuk memastikan bahwa hanya data yang berkaitan langsung dengan tujuan analisis yang dikumpulkan, sehingga dapat mengurangi kompleksitas dan meningkatkan efisiensi dari proses KDD.
2. **Pembersihan Data (*Data Cleaning/Preprocessing*):** Pada tahap ini dilakukan proses pembersihan data yang bertujuan untuk menghilangkan data yang tidak konsisten, *error*, nilai hilang/*null (missing value)* dan noise dari data yang sudah dipilih. Proses ini penting dikarenakan kualitas dari data yang buruk akan memiliki dampak langsung pada kualitas pola atau pengetahuan yang dihasilkan nantinya.
3. **Transformasi Data (*Data Transformation*):** Pada tahap transformasi, data yang telah mengalami proses pembersihan atau *data cleaning*, akan diubah ke dalam bentuk format yang sesuai untuk proses *data mining* (proses ini mencakup normalisasi dan *encoding*).
4. **Proses Modelling Data (*Data Mining*):** Tahap ini merupakan proses inti dari metode KDD, yaitu dengan melakukan ekstraksi pola, aturan ataupun model dari data dengan menggunakan teknik dan algoritma *data mining*.
5. **Evaluasi Pola (*Pattern Evaluation*):** Pada tahap ini, dilakukan evaluasi terhadap pola atau model yang telah ditemukan, kemudian dinilai untuk mengetahui apakah benar-benar dapat berguna dan relevan. Proses ini melibatkan pengukuran performa seperti; *precision*, *recall*, RMSE, MAE, dan MAPE.
6. **Representasi Pengetahuan (*Knowledge Representation*):** Pada tahap terakhir ini, menyajikan pengetahuan yang ditemukan dalam format yang dapat dimengerti oleh *end user* atau pengguna akhir (manajer, para analis

atau sistem keputusan *automatic base*. Bentuk penyajiannya dapat berupa; visualisasi grafik atau diagram, laporan dalam bentuk *automated text*, integrasi kedalam sistem *decision support* dengan tujuan agar hasil dari metode KDD ini bisa dimanfaatkan dalam pengambilan keputusan, investasi ataupun strategi bisnis dalam bentuk pola grafik visualisasi ataupun *dashboard* visualisasi yang berdasarkan demografi.

2.3.2 LSTM (Long-Short Term Memory)

Pada tabel 2.2 merupakan tabel yang berisikan variabel rumus, definisi dan nilai ukur yang digunakan pada rumus-rumus dasar pada algoritma dasar LSTM, yang mencakup elemen-elemen penting seperti *input*, *output*, *gate*, bobot, dan bias yang memiliki peran dalam proses pembelajaran dan prediksi deret waktu (*time series*).

Sumber: [10]

Tabel 2.3 Definisi variabel rumus

Variabel	Penjelasan	Nilai
c_t	<i>Cell state</i> pada waktu t , gabungan antara informasi lama dan informasi baru melalui <i>forget gate</i> dan <i>input gate</i>	\mathbb{R}
h_t	<i>Hidden state</i> atau <i>output</i> LSTM pada waktu t	$[-1, 1]$
\hat{h}_t	<i>Output</i> aktivasi dari <i>cell state</i> c_t menggunakan fungsi aktivasi ψ	$[-1, 1]$
z_t	Input kandidat memori baru setelah fungsi aktivasi ϕ diterapkan pada \hat{z}_t	\mathbb{R}
\hat{z}_t	Kombinasi linear dari input x_t dan hidden state sebelumnya h_{t-1} , dikontrol oleh bobot ω_z dan r_z serta bias b_z	\mathbb{R}
i_t	Input gate, menentukan seberapa banyak informasi baru (z_t) yang ditambahkan ke cell state	$[0, 1]$
\hat{i}_t	Nilai sebelum aktivasi sigmoid pada input gate	\mathbb{R}

Variabel	Penjelasan	Nilai
f_t	Forget gate, menentukan seberapa banyak informasi lama (c_{t-1}) yang disimpan	[0, 1]
\hat{f}_t	Nilai sebelum aktivasi sigmoid pada forget gate	R
o_t	Output gate, menentukan seberapa banyak dari cell state yang digunakan sebagai output (h_t)	[0, 1]
\hat{o}_t	Nilai sebelum aktivasi sigmoid pada output gate	R
Sigmoid (σ)	Memiliki interval nilai [0,1], jika mendekati 0 akan dihapuskan, dan dilanjutkan jika nilainya 1	[0,1]

Pada simbol rumus variabel, dijelaskan beberapa variabel yang baik dalam mengatur aliran informasi seperti *input gate* (i_t), *forget gate* (f_t), dan *output gate* (o_t), maupun dalam proses pembaruan memori seperti *cell state* (c_t) dan *hidden state* (h_t)[18]. Selain itu, ditampilkan juga nilai-nilai interval yang digunakan, seperti [0,1] untuk fungsi aktivasi sigmoid dan [-1,1] untuk representasi *output*, yang berguna memberikan pemahaman yang lebih mendalam terhadap perhitungan internal dalam arsitektur LSTM. Tabel diatas merupakan dasar pemahaman penting sekaligus juga rumus dasar pada kedua metode sebelum membandingkan kinerja LSTM dengan varian algoritma kembangan seperti xLSTM.

Long short-term memory network (LSTM) merupakan algoritma atau metode modifikasi yang berasal dari *Recurrent Neural Network* atau RNN. Banyak modifikasi dari RNN, tetapi LSTM merupakan salah satu algoritma yang populer diantaranya. LSTM digunakan untuk melengkapi kekurangan RNN yang dimana RNN tidak dapat memprediksi kata berdasarkan informasi lampau yang disimpan dalam jangka waktu yang lama (*time-series*) [19].

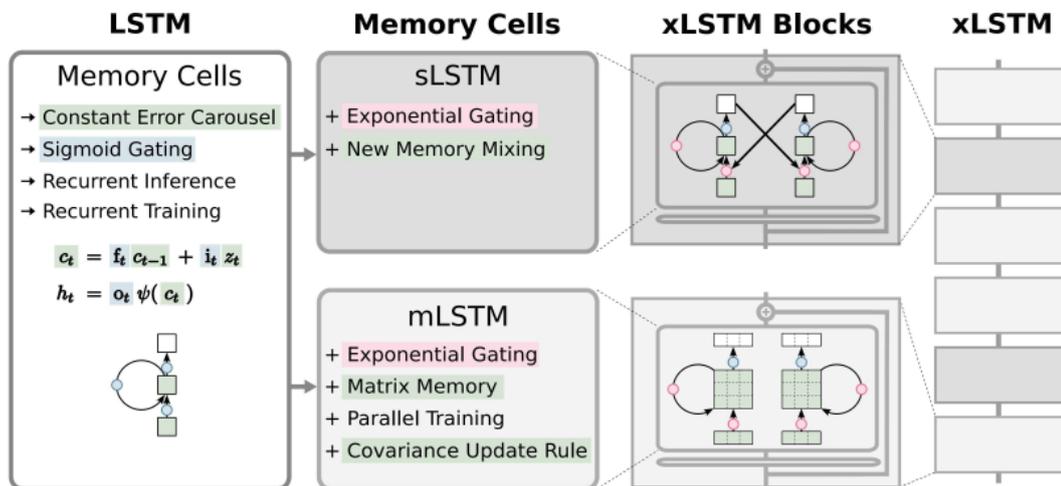
$c_t = f_t c_{t-1} + i_t z_t$		cell state
$h_t = o_t \hat{h}_t$,	$\hat{h}_t = \psi(c_t)$	hidden state
$z_t = \varphi(\hat{z}_t)$,	$\hat{z}_t = \omega_z^T x_t + r_z h_{t-1} + b_z$	cell input
$i_t = \sigma(\hat{i}_t)$,	$\hat{i}_t = \omega_i^T x_t + r_i h_{t-1} + b_i$	input gate
$f_t = \sigma(\hat{f}_t)$,	$\hat{f}_t = \omega_f^T x_t + r_f h_{t-1} + b_f$	forget gate
$o_t = \sigma(\hat{o}_t)$,	$\hat{o}_t = \omega_o^T x_t + r_o h_{t-1} + b_o$	output gate

Rumus 2.1 LSTM

Sumber: [20]

Algoritma LSTM mampu mengingat sekumpulan informasi yang sudah disimpan dalam jangka waktu yang panjang, sekaligus juga menghapus informasi yang tidak lagi relevan. LSTM sangat efisien dalam melakukan proses, memprediksi, sekaligus melakukan klasifikasi data yang berdasarkan urutan waktu atau *time-series* tertentu dibandingkan dengan algoritma yang sebelumnya yaitu algoritma RNN [19].

2.3.3 xLSTM (Extended Long-Short Term Memory)



Gambar 2.2 xLSTM Architecture

Sumber: [20]

Pada gambar 2.2 merupakan gambaran dari alur evolusi arsitektur xLSTM, dimulai dari kiri hingga ke kanan, yang paling kiri merupakan LSTM tradisional

atau klasik, lalu arsitektur berkembang menjadi dua varian LSTM yaitu algoritma sLSTM dan mLSTM yang kemudian kedua varian ini digunakan sebagai dasar dalam susunan blok xLSTM, blok ini kemudian disusun secara bertingkat (*stacked*) dan akhirnya menghasilkan arsitektur xLSTM penuh yang bersifat modular, efisien dan dirancang sebagai algoritma pemodelan konteks jangka panjang. Dapat dilihat pada gambar yang paling kanan, gambar tersebut merupakan susunan blok arsitektur xLSTM sehingga terbentuk xLSTM.

Extended Long short-term memory (xLSTM) merupakan algoritma modifikasi yang merupakan arsitektur lanjutan dari LSTM yang dikembangkan dengan menggabungkan dua varian LSTM itu sendiri, yaitu sLSTM (*Scalar LSTM*) dan mLSTM (*Matrix LSTM*)[20]. sLSTM menggunakan memori skalar yang ringan dan efisien untuk merangkum informasi dalam ruang asli, sedangkan mLSTM menggunakan memori berbasis matriks yang memungkinkan kapasitas memori lebih besar dan pemrosesan paralel yang efisien dalam ruang berdimensi tinggi. Kombinasi keduanya dalam arsitektur xLSTM memberikan fleksibilitas dalam merangkum konteks sekuensial baik di ruang rendah maupun tinggi, sehingga model dapat menangani berbagai jenis data dengan kompleksitas temporal yang beragam secara lebih efektif dibandingkan LSTM tradisional. Berikut ini merupakan penjelasan beserta rumus dari sLSTM dan mLSTM:

a) sLSTM (*Scalar Long Short-Term Memory*)

$C_t = f_t c_{t-1} + i_t z_t$		cell state
$n_t = f_t n_{t-1} + i_t$		normalizer state
$h_t = o_t \hat{h}_t,$	$\hat{h}_t = c_t / n_t$	hidden state
$z_t = \varphi(\hat{z}_t),$	$\hat{z}_t = \omega_z^T x_t + r_z h_{t-1} + b_z$	cell input
$i_t = \exp(\hat{i}_t),$	$\hat{i}_t = \omega_i^T x_t + r_i h_{t-1} + b_i$	input gate
$f_t = \sigma(\hat{f}_t) \text{ or } \exp(\hat{f}_t),$	$\hat{f}_t = \omega_f^T x_t + r_f h_{t-1} + b_f$	forget gate
$o_t = \sigma(\hat{o}_t),$	$\hat{o}_t = \omega_o^T x_t + r_o h_{t-1} + b_o$	output gate

Rumus 2.2 sLSTM

Sumber: [20]

sLSTM (*Scalar LSTM*) merupakan varian dari LSTM yang dirancang untuk menyederhanakan struktur memori dan memperkuat kemampuan pada model dalam mengelola informasi *sequential*. Tidak seperti LSTM standar yang menggunakan vektor untuk memori *internal*, sLSTM ini menggunakan memori skalar, yang bentuknya lebih ringan dan efisien secara komputasi. Meski lebih sederhana, sLSTM tetap mempertahankan kemampuannya untuk menyimpan dan memperbaharui informasi kontekstual secara bertahap dalam suatu urutan atau *sequence*[20].

b) mLSTM (Matric Long Short-Term Memory)

$$C_t = f_t C_{t-1} + i_t v_t k_t^T \quad \text{cell state} \quad (19)$$

$$n_t = f_t n_{t-1} + i_t k_t \quad \text{normalizer state} \quad (20)$$

$$h_t = o_t \hat{h}_t, \quad \hat{h}_t = C_t / q_t / \max\{|n_t^T q_t|, 1\} \quad \text{hidden state} \quad (21)$$

$$q_t = W_q x_t + b_q \quad \text{query input} \quad (22)$$

$$k_t = \frac{1}{\sqrt{d}} W_k x_t + b_k \quad \text{key input} \quad (23)$$

$$v_t = W_k x_t + b_q \quad \text{value input} \quad (24)$$

$$i_t = \exp(\hat{i}_t), \quad \hat{i}_t = W_k x_t + b_i \quad \text{input gate} \quad (25)$$

$$f_t = \sigma(\hat{f}_t) \text{ or } \exp(\hat{f}_t), \quad \hat{f}_t = W_k x_t + b_f \quad \text{forget gate} \quad (26)$$

$$o_t = \sigma(\hat{o}_t), \quad \hat{o}_t = W_k x_t + b_o \quad \text{output gate} \quad (27)$$

Rumus 2.3 mLSTM

Sumber: [20]

mLSTM (*Matrix LSTM*) merupakan salah satu varian dari LSTM yang menggunakan struktur memori berbasis matriks, seperti skalar atau vektor yang ada pada LSTM biasa dan sLSTM. Tujuan hadirnya mLSTM adalah untuk meningkatkan kapasitas memori dan memperluas kemampuan representasi konteks, terutama didalam ruang berdimensi tinggi, sehingga model dapat menyimpan dan memproses informassi yang lebih rumit atau kompleks secara efisien[20].

2.3.4 Evaluation Metrics

Pada penelitian ini digunakan juga metrik evaluasi yang digunakan sebagai alat ukur dalam menilai performa algoritma yang digunakan untuk dilakukan analisis, yang dijabarkan dibawah ini:

a) Root Mean Square Error (RMSE)

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2}$$

(nilai terbaik = 0; nilai terburuk = $+\infty$)

Rumus 2.4 Root Mean Square Error (RMSE)

Sumber: [21]

Kedua besaran MSE dan RMSE berhubungan secara linear (melalui akar kuadrat). Pengurutan model regresi berdasarkan MSE akan identik dengan pengurutan model berdasarkan RMSE [21].

b) Mean Square Error (MSE)

$$MSE = \frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2$$

(nilai terbaik = 0; nilai terburuk = $+\infty$)

Rumus 2.5 Mean Square Error (MSE)

Sumber: [21]

MSE dapat digunakan jika ada data yang berbeda secara signifikan yang perlu dideteksi. Faktanya, MSE sangat bagus untuk mengaitkan bobot yang lebih besar pada titik-titik tersebut, dikarenakan norma L2: jelas, jika model pada akhirnya menghasilkan satu prediksi yang sangat buruk, bagian kuadrat dari fungsi tersebut akan memperbesar kesalahannya [21].

c) Mean Absolute Error (MAE)

$$MAE = \frac{1}{m} \sum_{i=1}^m |X_i - Y_i|$$

(nilai terbaik = 0; nilai terburuk = $+\infty$)

Rumus 2.6 Mean Absolute Error (MAE)

Sumber: [21]

MAE dapat digunakan jika ada data yang berbeda secara signifikan mewakili bagian data yang rusak. Faktanya, MAE tidak menghukum terlalu banyak *outlier* pelatihan (norma L1 entah bagaimana menghaluskan semua kesalahan dari *outlier* yang mungkin terjadi), sehingga memberikan ukuran kinerja yang umum dan terbatas untuk model. Di sisi lain, jika set pengujian juga memiliki banyak pencilan, kinerja model akan biasa-biasa saja [21].

d) Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{Y_i - X_i}{Y_i} \right|$$

(nilai terbaik = 0; nilai terburuk = $+\infty$)

Rumus 2.7 Mean Absolute Percentage Error (MAPE)

Sumber: [21]

MAPE adalah metrik kinerja lain untuk model regresi, memiliki interpretasi yang sangat intuitif dalam hal kesalahan relatif: karena definisinya, penggunaannya direkomendasikan dalam tugas-tugas di mana lebih penting untuk peka terhadap variasi relatif daripada variasi absolut [21].

e) R-Squared

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i)^2}{\sum_{i=1}^m (\bar{Y} - Y_i)^2}$$

(worst value = $-\infty$; best value = +1)

Rumus 2.8 R-Squared (R^2)

Sumber: [21]

The coefficient of determination dapat diartikan sebagai proporsi varians dalam variabel dependen yang dapat diprediksi dari variabel independen, dan dapat mengambil nilai dalam rentang $(-\infty, 1]$ sesuai dengan hubungan timbal balik antara *ground truth* dan model prediksi [21].

- **$R^2 \geq 0$** : Dengan regresi linier tanpa kendala, R^2 adalah non-negatif dan berhubungan dengan kuadrat dari koefisien korelasi berganda [21].
- **$R^2 = 0$** : Garis yang cocok (atau *hyperplane*) adalah *horizontal*. Dengan dua variabel numerik, hal ini terjadi jika variabel-variabel tersebut independen, yaitu tidak berkorelasi [21].

2.3.5 Forecasting

Forecasting adalah sebuah teknik yang dipakai untuk mengumpulkan dan memanipulasi data dengan tujuan untuk merumuskan prakiraan yang akurat. Metode ini mengandalkan berbagai jenis data sebagai dasar untuk melakukan prediksi. Metode *forecasting*, sama dengan metode estimasi pada label, target atau *class* yang bertipe numerik [3], yang dimana perbedaannya data yang digunakan merupakan data rentang waktu (*data time-series*) [22].

2.4 Tools dan Software

Pada penelitian ini, penggunaan *tools* dan *software* memiliki peran yang penting dalam mendukung proses pengolahan data, pemodelan dan evaluasi hasil metode secara sistematis dan efisien. Penggunaan *tools* ini tidak hanya mempercepat proses pengembangan dan evaluasi hasil saja, tetapi membantu untuk memastikan bahwa seluruh tahapan penelitian dilakukan secara baik dan benar sehingga bisa terjadinya proses pengambilan keputusan dan hasil yang sangat baik. Beberapa *tools* dan *software* yang digunakan adalah sebagai berikut:

2.4.1 Yahoo Finance

Merupakan situs web yang menyediakan berbagai informasi dan berita tentang pasar keuangan, bisnis, dan ekonomi. Yahoo Finance menawarkan alat-alat atau *tools* yang dapat digunakan dalam mengelola portofolio, mengakses data pasar, sekaligus berinteraksi dengan berbagai komunitas secara daring atau *online*. Jadi

Yahoo Finance adalah salah satu *website* sumber terbesar dan terpopuler untuk data keuangan di dunia[23].

2.4.2 Microsoft Excels

Merupakan program perangkat lunak *spreadsheet* yang memungkinkan para pengguna untuk mengorganisir, menganalisis, dan memvisualisasikan data. Excel memiliki banyak fitur, seperti; formula, fungsi, grafik, dan tabel pivot, yang dapat membantu para penggunanya dalam melakukan perhitungan, manajemen proyek dan pembuatan anggaran.

2.4.3 Google Colab

Merupakan aplikasi berbasis *web open-source* yang memungkinkan para penggunanya untuk *create* atau membuat sekaligus juga berbagi dokumen yang berisikan kode langsung, visualisasi dan teks naratif.

2.4.4 Python

Merupakan sebuah bahasa pemrograman pada perangkat lunak yang dimana memungkinkan penggunanya untuk membuat sekaligus juga berbagi dokumen interaktif yang berisikan kode, teks dan gambar. Dan juga Python merupakan salah satu dari lebih, dari 40 bahasa pemrograman yang didukung oleh Jupyter Notebook dan Google colab. Python biasanya digunakan untuk menganalisis data, visualisasi data, pembelajaran mesin atau *machine learning*.

U M N
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