

## BAB II

### KAJIAN LITERATUR

#### 2.1 Tinjauan Pustaka

Bagian ini berisi landasan teori berkaitan dengan teori-teori yang digunakan untuk mendukung penyelesaian penelitian yang akan dilakukan dan penelitian yang sudah dilakukan oleh peneliti sebelumnya.

Pembahasan akan dimulai dengan pengenalan mengenai *cryptocurrency* dan Bitcoin pada subbab 2.1.1. Pada bagian subbab 2.1.2 akan membahas mengenai prediksi *cryptocurrency* Bitcoin. Pada bagian 2.1.3 akan membahas *machine learning*. Pada subbab 2.1.4 akan membahas *Artificial Neural Network* (ANN), kemudian dilanjutkan pada subbab 2.1.5 tentang *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM) pada 2.1.6. Pada subbab 2.1.7 akan membahas hybrid model CNN-LSTM yang akan digunakan untuk melakukan evaluasi terhadap model dan terakhir pada subbab 2.1.8 membahas Parameter Model Prediksi.

#### 2.1.1 Cryptocurrency dan Bitcoin

*Cryptocurrency* merupakan mata uang digital berbasis kriptografi yang dioperasikan secara desentralisasi melalui jaringan *Blockchain* bertindak sebagai buku besar digital terdistribusi yang menyimpan seluruh transaksi dalam blok-blok terenkripsi dan terhubung secara kronologis, sehingga dapat menjamin keamanan dan transparansi [13]. Bitcoin adalah *cryptocurrency* pertama dan paling populer yang telah menjadi subjek perhatian utama baik dalam dunia keuangan maupun teknologi. Nilai Bitcoin sangat dipengaruhi oleh permintaan pasar, tingkat adopsi pengguna, dan sentimen global. Salah satu tantangan utama dalam perdagangan Bitcoin adalah volatilitas harganya yang tinggi, yang menjadikan prediksi harga Bitcoin sebagai topik penting dalam berbagai studi [4]. Beberapa studi menyatakan bahwa karakteristik Bitcoin berbeda secara signifikan dari aset tradisional lainnya, termasuk saham dan mata uang fiat. Karena pergerakan harga yang tidak teratur dan volatil, banyak peneliti mulai menerapkan pendekatan berbasis *Machine Learning* dan *Deep Learning* untuk menganalisis serta memprediksi harga Bitcoin secara lebih akurat [5].

### 2.1.2 Prediksi Cryptocurrency Bitcoin

Prediksi harga *cryptocurrency*, khususnya Bitcoin, merupakan topik yang semakin penting seiring dengan meningkatnya minat terhadap aset digital ini. Fluktuasi harga Bitcoin yang tinggi membuatnya menjadi subjek ideal untuk eksplorasi metode prediksi berbasis data [14].

Pendekatan tradisional dalam prediksi harga seperti analisis teknikal dan fundamental dianggap kurang mampu menangkap kompleksitas pola pergerakan harga Bitcoin yang sangat volatil. Oleh karena itu, pendekatan berbasis data seperti *Machine Learning* dan *Deep Learning* semakin sering digunakan dalam penelitian terkini. Beberapa studi telah mengembangkan model prediksi yang mampu memproses data historis harga, volume transaksi, sentimen pasar, dan indikator teknikal lainnya untuk menghasilkan prediksi yang lebih akurat. Teknik seperti ANN, LSTM, dan CNN-LSTM hybrid menunjukkan kinerja yang menjanjikan dalam menangani data *time series* Bitcoin [15].

### 2.1.3 Machine Learning

*Machine Learning* (ML) merupakan cabang dari kecerdasan buatan yang berfokus pada kemampuan komputer untuk belajar dari data dan membuat prediksi atau pengambilan keputusan tanpa diprogram secara eksplisit. Secara definisi, ML adalah ilmu atau studi tentang algoritma dan model statistik yang digunakan oleh sistem komputer untuk melakukan tugas tertentu tanpa instruksi yang jelas. ML bergantung pada pola dan kesimpulan yang dihasilkan. Untuk mendapatkan pola dan kesimpulan ini, algoritma ML menciptakan model matematika berdasarkan data sampel, yang sering disebut sebagai '*training data*'. Pendekatan ML memungkinkan sistem untuk mengenali pola dan hubungan dalam data yang kompleks, menjadikannya sangat cocok untuk masalah prediksi harga yang memiliki karakteristik non-linear dan volatil seperti *cryptocurrency* [16]. Pemakaian teknik ini berkaitan dengan pembelajaran mesin dan AI. Mesin ini membuktikan kepada algoritma atau program yang berjalan di komputer. Oleh karena itu, semua pengetahuan *machine learning* pasti akan melibatkan data (Dinata & Hasdyna, 2020).

Di dalam ML ini juga terdapat 2 cara pembelajaran terkait bagaimana penentuan jenis data yang di *input*-kan yaitu : *Supervised Learning* dan *Unsupervised Learning* Dalam melakukan prediksi harga Bitcoin, ML digunakan untuk membangun model yang mampu mempelajari pola historis dari harga, volume perdagangan, dan faktor lain seperti sentimen pasar atau tren global. Berbagai algoritma ML seperti *Linear Regression*, *Decision Tree*, *Random Forest*, dan *Support Vector Machine* (SVM) telah banyak digunakan dalam studi

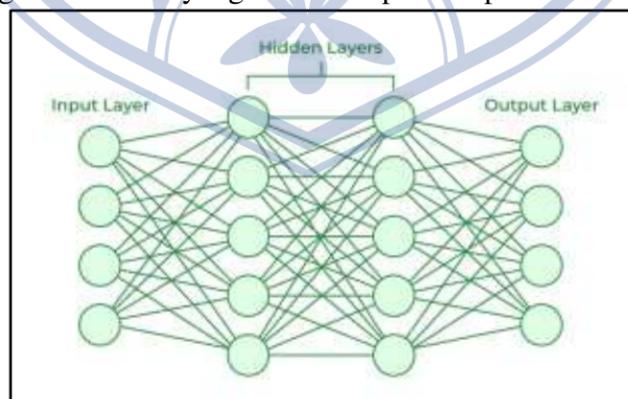
awal, namun seiring berkembangnya kebutuhan akan akurasi yang lebih tinggi, pendekatan *Deep Learning* semakin diminati[17] Keunggulan ML terletak pada kemampuannya dalam memproses data dalam jumlah besar dan mengenali pola yang tidak dapat ditangkap oleh pendekatan tradisional. Dalam banyak kasus, ML juga digunakan sebagai dasar awal untuk membangun model hybrid seperti CNN-LSTM yang menggabungkan kekuatan deteksi fitur dan pemrosesan sekuensial.

#### 2.1.4 Artificial Neural Network (ANN)

*Artificial Neural Network* (ANN) adalah salah satu metode dalam *machine learning* yang terinspirasi oleh cara kerja otak manusia, khususnya dalam hal bagaimana *neuron* biologis saling terhubung dan memproses informasi. ANN terdiri dari sejumlah *neuron* buatan (node) yang disusun dalam tiga lapisan utama: *input layer*, *hidden layer*, dan *output layer* [18].

Pada dasarnya, ANN memetakan input ke *output* melalui proses pembelajaran dari data historis. Masing-masing *neuron* dalam *layer* terhubung dengan *neuron* di *layer* lainnya melalui bobot (*weights*) yang dioptimalkan selama proses pelatihan. Fungsi aktivasi seperti ReLU (*Rectified Linear Unit*), *sigmoid*, atau *tanh* digunakan untuk memperkenalkan non-linearitas ke dalam model, yang penting dalam menangkap pola kompleks seperti fluktuasi harga Bitcoin [19].

ANN sering digunakan sebagai dasar model prediktif, terutama ketika data memiliki pola non-linier yang tidak mudah ditangani oleh model statistik tradisional. Dalam prediksi harga *cryptocurrency*, ANN mampu belajar dari data historis untuk menghasilkan prediksi harga yang mendekati kondisi aktual, meskipun dalam praktiknya model ini sering dikombinasikan dengan arsitektur yang lebih kompleks seperti LSTM atau CNN [20].



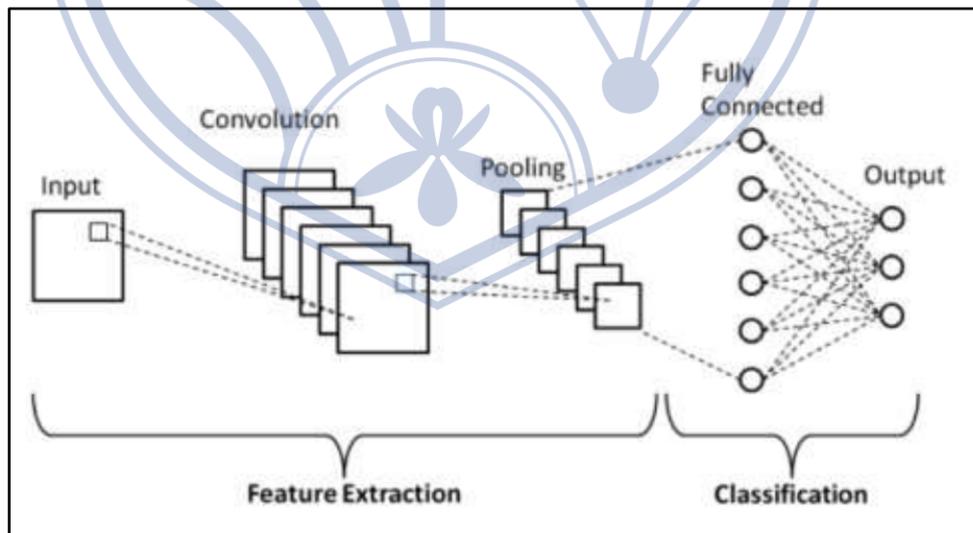
Gambar 2.1 Ilustrasi *Neuron* dalam ANN[19]

### 2.1.5 Convolutional Neural Network (CNN)

*Convolutional Neural Network* (CNN) awalnya dikembangkan untuk pengolahan citra dan pengenalan pola visual, namun arsitektur ini juga terbukti efektif untuk menangani data deret waktu (*time series*) seperti fluktuasi harga *cryptocurrency*. CNN bekerja dengan menerapkan *filter* (*kernel*) yang melintasi data *input* untuk mengekstraksi fitur lokal yang relevan [21]

Dalam melakukan prediksi harga Bitcoin, CNN mampu menangkap pola-pola lokal pada data historis seperti tren jangka pendek dan perubahan harga yang tajam. Lapisan konvolusional dalam CNN dapat mengenali struktur data tanpa perlu proses ekstraksi fitur manual, sementara lapisan *pooling* bertugas mereduksi dimensi data dan meningkatkan efisiensi pemrosesan [21], [22]

Kelebihan utama CNN terletak pada kemampuannya untuk mengekstraksi fitur spasial secara otomatis, sehingga model ini sering digunakan sebagai bagian dari arsitektur hybrid bersama LSTM dalam pemodelan data deret waktu keuangan. Dalam prediksi harga Bitcoin, CNN biasanya digunakan untuk menganalisis data dalam bentuk *window time-series* yang direpresentasikan sebagai vektor matriks *input*[23]. CNN dan ANN adalah dua cabang utama dari *neural network* yang digunakan untuk berbagai aplikasi. CNN yang sering digunakan dalam pengolahan citra dan pengenalan pola, memiliki lapisan konvolusi yang mampu mengekstrak fitur-fitur kompleks dari data input. Menurut Irmak, Alachiotis and Ziener(2021).

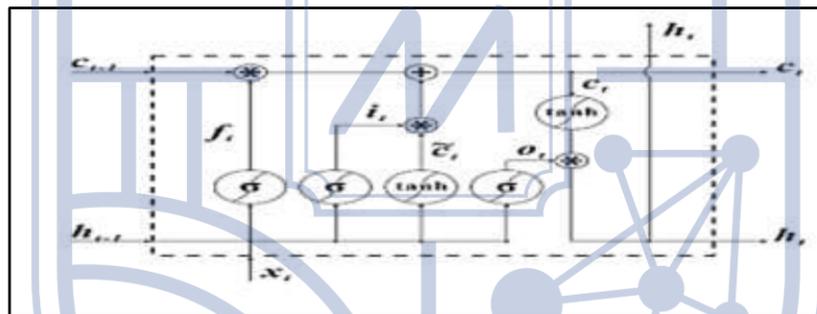


Gambar 2.2 sebuah diagram sederhana dari CNN [8]

### 2.1.6 Long Short-Term Memory (LSTM)

*Long Short-Term Memory* (LSTM) adalah jenis *Recurrent Neural Network* (RNN) yang dirancang khusus untuk mengatasi permasalahan *vanishing gradient* dalam pemrosesan data sekuensial jangka panjang [22]. LSTM memiliki arsitektur khusus yang memungkinkan model untuk mempertahankan informasi dari waktu sebelumnya yang relevan, sehingga sangat efektif dalam menangani data deret waktu seperti harga Bitcoin.

Arsitektur LSTM terdiri dari tiga gerbang utama: *input gate*, *forget gate*, dan *output gate*. Ketiga gerbang ini bekerja sama untuk mengontrol aliran informasi masuk dan keluar dari memori jangka panjang, serta menentukan informasi mana yang akan dipertahankan atau dilupakan [24]. Dalam prediksi harga Bitcoin, kemampuan ini sangat penting karena pola harga masa lalu dapat memiliki pengaruh signifikan terhadap harga di masa depan. Modul ini kemudian disempurnakan dan dipopulerkan oleh beberapa peneliti lainnya. Jaringan LSTM terdiri dari modul-modul dengan konsistensi berulang, mirip seperti RNN [25].



Gambar 2.3 Struktur sel memori LSTM pada lapisan tersembunyi[11]

Keterangan gambar 2.3 adalah sebagai berikut :

$i_t$  = *Input gate* menandakan bahwa informasi dalam sel akan diperbarui.

$f_t$  = *Forget gate* menandakan bahwa data dalam sel harus dihapus.

$o_t$  = Ukuran seberapa banyak data yang dikirim keluar dari sistem melalui *output gate*.

$\tilde{c}_t$  = Nilai potensial untuk status sel memori pada waktu  $t$ .

$c_t$  = Status sel memori saat ini pada waktu  $t$ , yang dihitung dari kombinasi antara  $i_t$  dan  $\tilde{c}_t$ , serta  $f_t$  dan  $c_{t-1}$  melalui operasi perkalian elemen-sejajar (*element-wise multiplication*).

$h_t$  = Nilai rata-rata dari keluaran setelah melalui *output gate*.

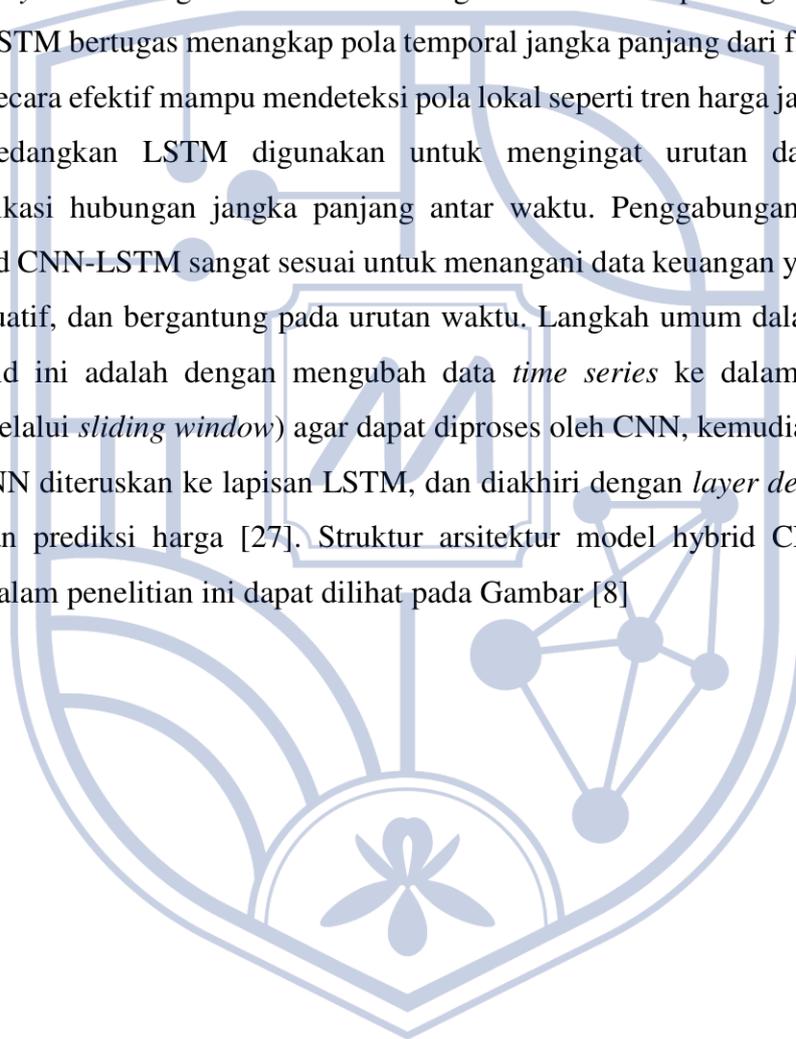
$\sigma$  = Merupakan singkatan dari fungsi sigmoid yang menerima nilai dan menempatkannya dalam rentang antara 0 hingga 1.

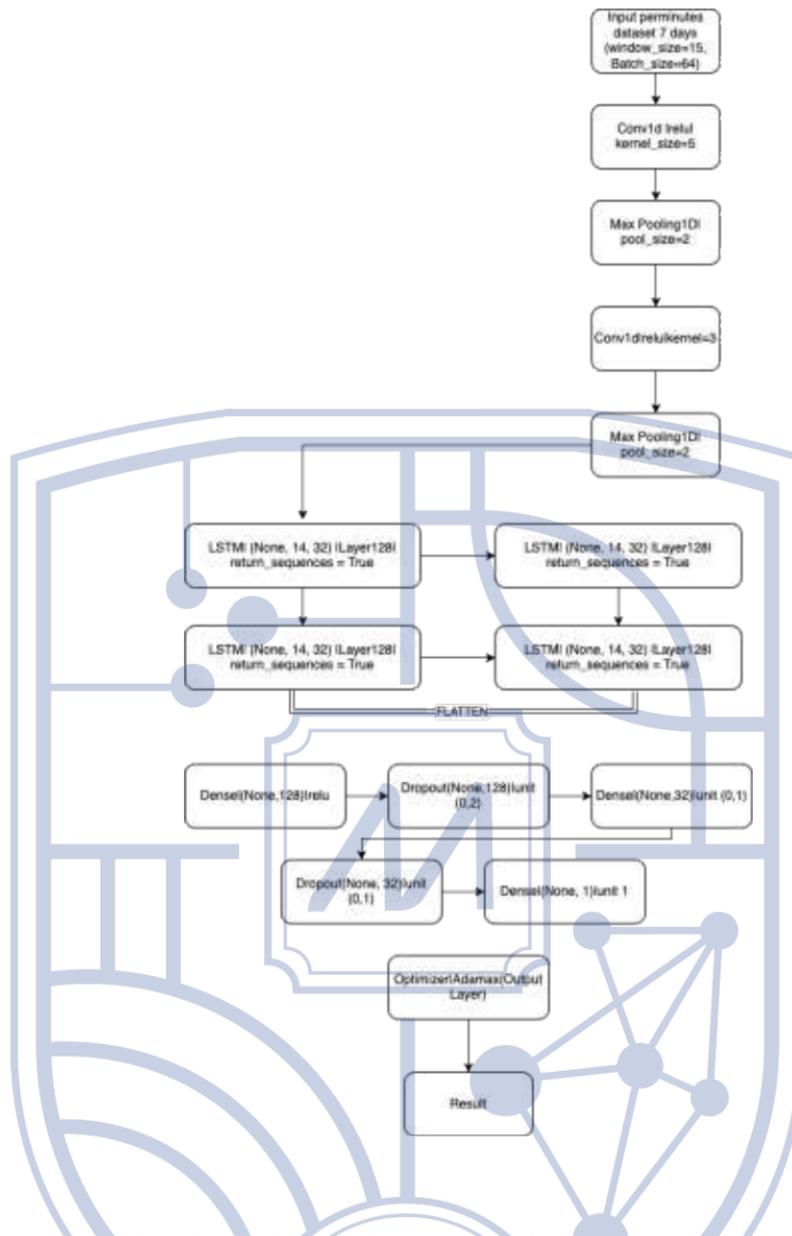
LSTM sangat populer dalam bidang keuangan dan telah banyak digunakan dalam berbagai penelitian prediksi harga saham maupun *cryptocurrency*. Model ini mampu menangkap

ketergantungan temporal yang kompleks, menjadikannya salah satu pendekatan paling efektif dalam analisis data keuangan non-linear yang sangat fluktuatif.

### 2.1.7 Hybrid Model CNN-LSTM

Model hybrid CNN-LSTM merupakan gabungan antara *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM), yang dirancang untuk mengatasi keterbatasan masing-masing model dalam tugas prediksi data deret waktu seperti harga *cryptocurrency*. CNN digunakan untuk mengekstraksi fitur penting dari data input, sementara LSTM bertugas menangkap pola temporal jangka panjang dari fitur-fitur tersebut [26]. CNN secara efektif mampu mendeteksi pola lokal seperti tren harga jangka pendek dan fluktuasi, sedangkan LSTM digunakan untuk mengingat urutan data historis dan mengidentifikasi hubungan jangka panjang antar waktu. Penggabungan ini menjadikan model hybrid CNN-LSTM sangat sesuai untuk menangani data keuangan yang bersifat non-linear, fluktuatif, dan bergantung pada urutan waktu. Langkah umum dalam implementasi model hybrid ini adalah dengan mengubah data *time series* ke dalam bentuk matriks (misalnya melalui *sliding window*) agar dapat diproses oleh CNN, kemudian hasil ekstraksi fitur dari CNN diteruskan ke lapisan LSTM, dan diakhiri dengan *layer dense/output* untuk menghasilkan prediksi harga [27]. Struktur arsitektur model hybrid CNN-LSTM yang digunakan dalam penelitian ini dapat dilihat pada Gambar [8]





Gambar 2.4 Arsitektur model CNN-LSTM[8]

Pada gambar 2.4 terdapat arsitektur detail dari model hybrid CNN-LSTM yang digunakan pada penelitian ini. Model ini dirancang untuk memanfaatkan keunggulan CNN dalam mengekstraksi pola lokal dari data deret waktu, serta keunggulan LSTM dalam memahami hubungan temporal jangka panjang antar data.

Pada tahap awal, data *input* berupa data harga Bitcoin selama periode tujuh hari diolah dalam bentuk *window* berukuran 15 dengan *batch size* 64. Data ini kemudian masuk ke blok CNN yang terdiri dari beberapa lapisan Conv1D dengan fungsi aktivasi ReLU dan *kernel size* masing-masing 5 dan 3. Lapisan konvolusi ini berfungsi mendeteksi fitur atau pola tren harga jangka pendek yang relevan. Setelah proses konvolusi, data melewati lapisan *MaxPooling1D* untuk mereduksi dimensi dan memfokuskan pada fitur-fitur terpenting.

Hasil dari blok CNN diteruskan ke blok LSTM. Di dalamnya terdapat dua jalur (*branch*) LSTM yang bekerja secara paralel. Masing-masing jalur LSTM terdiri dari dua *layer* LSTM berurutan dengan jumlah unit 128 dan pengaturan *return\_sequences=True* agar keluaran setiap langkah waktu dapat diteruskan ke *layer* berikutnya. Tujuan utama blok LSTM ini adalah menangkap pola keterkaitan urutan jangka panjang pada data *time series* yang tidak bisa ditangkap hanya dengan CNN saja.

Setelah melewati blok LSTM, *outputnya* disatukan dan diratakan melalui proses *Flatten*, kemudian dilanjutkan ke beberapa *Dense Layer* untuk melakukan pemetaan akhir. *Dense Layer* pertama berjumlah 128 unit dengan aktivasi ReLU, kemudian dilengkapi dengan lapisan *Dropout* untuk mengurangi risiko *overfitting*. Setelah itu, *output* diproses lagi melalui *Dense Layer* berunit 32, *Dropout* tambahan, dan diakhiri dengan *Dense Layer* berunit 1 yang berfungsi sebagai *output layer* untuk menghasilkan prediksi harga Bitcoin pada langkah waktu berikutnya. Proses *training* memanfaatkan *optimizer* Adamax yang sesuai untuk data *time series non-linear*.

Melalui arsitektur *hybrid* ini, pola lokal jangka pendek dapat dianalisis secara detail oleh CNN, sedangkan pola jangka panjang tetap terjaga melalui LSTM, sehingga diharapkan model dapat memberikan prediksi harga Bitcoin yang lebih akurat pada data yang fluktuatif dan bersifat *non-linear*.

### 2.1.8 Parameter Model Prediksi

Dalam membangun model prediksi harga Bitcoin berbasis *Deep Learning*, khususnya model hybrid CNN-LSTM, pemilihan dan penyesuaian parameter model (*hyperparameters*) sangat penting untuk memperoleh performa prediksi yang optimal. Parameter ini mempengaruhi kemampuan model dalam belajar dari data, menghindari *overfitting*, serta menghasilkan prediksi yang akurat.

Berikut adalah parameter-parameter utama yang umumnya digunakan dalam model prediksi CNN-LSTM:

#### 1. Jumlah Epoch

*Epoch* menunjukkan berapa kali seluruh *dataset* dilalui oleh model dalam proses pelatihan. Pemilihan jumlah *epoch* yang tepat akan memastikan model tidak *underfitting* maupun *overfitting*. Dalam studi [28], model LSTM dilatih selama 50 hingga 200 *epoch* tergantung pada kompleksitas data dan arsitektur jaringan.

## 2. Batch Size

*Batch size* mengacu pada jumlah sampel data yang diproses sebelum model memperbarui bobotnya. Pemilihan *batch size* yang terlalu besar dapat menyebabkan generalisasi yang buruk, sementara *batch size* yang terlalu kecil membuat proses pelatihan menjadi lambat. Nilai umum yang digunakan dalam literatur adalah 32, 64, atau 128 .

## 3. Learning Rate

*Learning rate* menentukan seberapa besar langkah pembaruan bobot jaringan saat melakukan backpropagation. *Learning rate* yang terlalu besar dapat menyebabkan model tidak stabil, sedangkan *learning rate* yang terlalu kecil membuat konvergensi terlalu lambat. Biasanya digunakan nilai antara 0.001 hingga 0.0001 dalam model CNN-LSTM.

## 4. Optimizer

*Optimizer* adalah algoritma yang digunakan untuk meminimalkan fungsi *loss*. *Optimizer* populer untuk model CNN-LSTM adalah **Adam**, karena efisiensinya dalam menangani data *time series* dan adaptif terhadap perubahan *learning rate*

## 5. Activation Function

Fungsi aktivasi menentukan *output* dari setiap *neuron*. ReLU (*Rectified Linear Unit*) umumnya digunakan di lapisan CNN untuk mempercepat konvergensi, sementara LSTM menggunakan *sigmoid* atau *tanh* dalam *gate*-nya untuk menjaga stabilitas memori.

## 6. Time Steps / Look Back

*Time step* adalah jumlah periode historis yang digunakan untuk membuat satu prediksi. Misalnya, model dapat melihat data harga 30 hari ke belakang untuk memprediksi harga hari ke-31. Pemilihan *time step* yang terlalu sedikit bisa membuat model kehilangan konteks temporal penting, sedangkan *time step* yang terlalu banyak berisiko meningkatkan kompleksitas model[29].

## 7. Struktur Layer

Struktur *layer* dalam model hybrid CNN-LSTM [25]dirancang untuk memanfaatkan kekuatan masing-masing arsitektur dalam menangani data *time series*. CNN digunakan untuk mengekstraksi fitur spasial dari data historis, sedangkan LSTM menangkap hubungan temporal atau ketergantungan waktu antar data.Umumnya, struktur *layer* dalam model prediksi harga Bitcoin berbasis CNN-LSTM terdiri dari:

### a. Convolutional Layer

*Layer* ini berfungsi mengekstraksi pola penting dari *input* data, seperti tren harga atau pola volume dalam rentang waktu tertentu. Biasanya digunakan 1-2 convolutional *layers* dengan

*filter* berukuran kecil (misalnya 3 atau 5) dan aktivasi ReLU untuk meningkatkan non-linearitas dan efisiensi komputasi.

#### b. MaxPooling Layer

Digunakan setelah convolutional *layer* untuk mengurangi dimensi data dan menjaga fitur penting. Hal ini membantu mengurangi beban komputasi dan mencegah *overfitting*.

#### c. LSTM Layer

Lapisan ini bertugas mengenali pola urutan dalam data *time series*, seperti fluktuasi harga harian atau mingguan. Model dapat menggunakan satu atau lebih LSTM *layer* dengan unit yang bervariasi (misalnya 50-100), tergantung pada kompleksitas data dan panjang *time step*.

#### d. Dropout Layer

Untuk mengurangi *overfitting*, *dropout layer* biasanya disisipkan antara LSTM atau *Dense layer*. Nilai *dropout* umum berkisar antara 0.2 hingga 0.5.

#### e. Dense (Fully Connected) Layer

Lapisan ini menghasilkan *output* akhir berupa prediksi harga. Biasanya menggunakan satu *neuron* (unit) jika target adalah nilai harga tunggal, dengan fungsi aktivasi linear. Desain arsitektur model harus disesuaikan dengan karakteristik *dataset*, jumlah fitur *input*, dan target prediksi. Penyesuaian jumlah *layer*, jumlah *neuron*, dan konfigurasi lainnya sangat penting untuk memastikan model memiliki kapasitas representasi yang cukup tanpa *overfitting*.

## 2.2 Penelitian Sebelumnya

Penelitian mengenai prediksi harga Bitcoin menggunakan pendekatan *Machine Learning* dan *Deep Learning* telah banyak dilakukan dalam beberapa tahun terakhir. Beberapa studi terdahulu mengembangkan model prediktif berbasis *neural network* untuk menangani karakteristik data *time series* yang kompleks dan volatil.

Penelitian oleh Jha dan Yadav (2021) mengembangkan model hybrid CNN-LSTM untuk memprediksi harga Bitcoin dan membandingkannya dengan model LSTM dan CNN tunggal. Hasilnya menunjukkan bahwa arsitektur hybrid memberikan hasil prediksi yang lebih akurat dibandingkan model individual. Selanjutnya, Sharma et al. (2022) mengusulkan pendekatan prediksi harga Bitcoin dengan menggabungkan CNN untuk ekstraksi fitur dan LSTM untuk memproses ketergantungan temporal. Studi ini menyoroti pentingnya *preprocessing* dan parameter *tuning* untuk meningkatkan akurasi.

Penelitian oleh Kim et al. (2021) memanfaatkan data historis harga dan volume

transaksi untuk membangun model prediksi menggunakan *Deep Learning*. Mereka membandingkan performa model LSTM, GRU, dan CNN-LSTM, dan menyimpulkan bahwa CNN-LSTM menunjukkan performa yang stabil dalam data volatil. Sementara itu, Jang dan Lee (2020) melakukan prediksi harga Bitcoin menggunakan *Deep Learning* model dengan *input* berupa indikator teknikal. Hasil studi mereka menunjukkan bahwa *deep neural network* dapat mengatasi non-linearitas data pasar kripto. Terakhir, penelitian oleh Tiwari dan Kumar (2023) memperluas pendekatan hybrid CNN-LSTM dengan menambahkan attention mechanism dan menunjukkan bahwa pendekatan ini mampu meningkatkan akurasi prediksi harga *cryptocurrency* secara signifikan dibandingkan *baseline* model.

Penelitian-penelitian ini menjadi dasar penting bagi pengembangan model prediksi harga Bitcoin yang lebih andal, serta membuktikan potensi pendekatan hybrid dalam menangani tantangan data *time series* yang kompleks dan dinamis. Adapun perbandingan penelitian sebelumnya dapat terlihat pada tabel 2.1

Tabel 2.1 Perbandingan penelitian sebelumnya

Judul Penelitian	Metode	Dataset	Hasil
Hybrid Deep Learning Model for Bitcoin Price Prediction (Jha & Yadav, 2022)	CNN-LSTM, LSTM, CNN	Data historis harga Bitcoin dari Yahoo Finance (2015–2020)	CNN-LSTM mengungguli model tunggal dengan RMSE terendah.
Bitcoin Price Prediction Using Hybrid CNN-LSTM Model (Sharma et al., 2022)	CNN-LSTM	Data harga harian Bitcoin, 2014–2021	CNN-LSTM berhasil memprediksi harga dengan akurasi tinggi, terutama setelah normalisasi dan hyperparameter tuning.
Comparative Analysis of Deep Learning Models for Bitcoin Price Prediction (Kim et al., 2021)	LSTM, GRU, CNN-LSTM	Data historis harga dan volume BTC	CNN-LSTM lebih stabil dibandingkan GRU dan LSTM tunggal.
Modeling and Prediction of Bitcoin Prices with Bayesian Neural Networks (Jang & Lee, 2020)	Deep Neural Network, BNN	Data blockchain dan harga Bitcoin	Deep learning lebih akurat daripada model statistik konvensional.

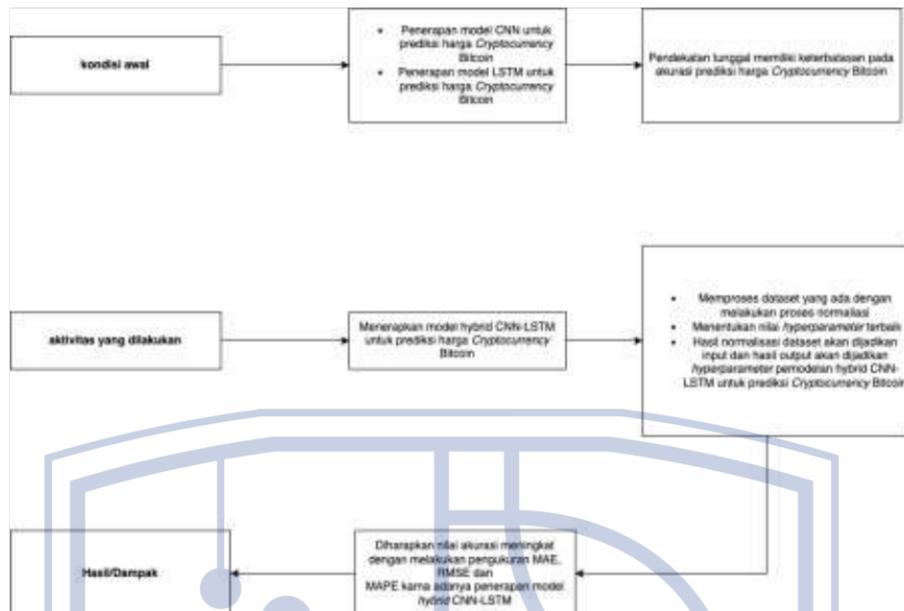
Tabel 2.1 Perbandingan penelitian sebelumnya(sambungan)

Judul Penelitian	Metode	Dataset	Hasil
Attention-Based CNN-LSTM Model for Cryptocurrency Price Forecasting (Tiwari & Kumar, 2023)	CNN-LSTM dengan Attention	Data harga kripto multi-sumber	Penambahan attention meningkatkan akurasi prediksi secara signifikan.

### 2.3 Kerangka Konseptual

Kerangka konsep dalam penelitian ini disusun berdasarkan kajian literatur dan temuan empiris dari penelitian terdahulu yang menunjukkan bahwa pendekatan berbasis *Deep Learning*, khususnya model CNN dan LSTM yang memiliki performa menjanjikan dalam menangani data *time series* seperti harga Bitcoin. Namun, penggunaan model tersebut secara terpisah masih memiliki sejumlah keterbatasan. Model LSTM unggul dalam menangkap pola temporal jangka panjang, namun tidak dirancang untuk mengekstraksi pola lokal atau spasial. Sementara itu, CNN memiliki keunggulan dalam mendeteksi pola spasial pendek namun tidak mempertimbangkan urutan waktu secara utuh. Oleh karena itu, diperlukan pendekatan gabungan yang mampu mengatasi keterbatasan masing-masing metode.

Dalam penelitian ini mengusulkan pendekatan hybrid CNN-LSTM sebagai solusi yang mengintegrasikan kemampuan ekstraksi fitur spasial dari CNN dan kemampuan menangkap pola temporal dari LSTM. Proses penelitian ini diawali dengan pengumpulan data historis harga Bitcoin dari sumber terpercaya seperti *Yahoo Finance*, mencakup fitur-fitur seperti *open, high, low, close, dan volume*. Data tersebut kemudian melalui tahapan pra-pemrosesan, termasuk pembersihan nilai kosong, normalisasi menggunakan *Min-Max Scaling*, serta pembentukan urutan data dengan pendekatan *sliding window*.



Gambar 2.5 Kerangka Konseptual

Selanjutnya, data yang telah diproses digunakan sebagai *input* untuk arsitektur model hybrid CNN-LSTM, di mana CNN berperan sebagai lapisan awal untuk mengekstraksi pola lokal dalam data, dan hasilnya diteruskan ke LSTM untuk memahami urutan waktu dan korelasi antar waktu. Model ini kemudian dilatih menggunakan data latih dengan konfigurasi *hyperparameter* tertentu seperti *learning rate*, *batch size*, dan jumlah *epoch*. Setelah proses pelatihan, model diuji menggunakan data uji dan kinerjanya dievaluasi dengan metrik regresi seperti *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Hasil dari pendekatan ini diharapkan dapat memberikan peningkatan akurasi dalam memprediksi harga Bitcoin, khususnya dibandingkan dengan model tunggal CNN atau LSTM. Selain itu, model hybrid ini diharapkan mampu menangani fluktuasi pasar yang ekstrem dengan lebih baik dan dapat dijadikan fondasi untuk pengembangan sistem prediksi harga *cryptocurrency* yang lebih adaptif dan presisi di masa mendatang.