

Prediksi Pergerakan Harga Pasar Modal dengan *Convolutional Neural Network (CNN)*

Yohanes Jhouma Parulian N
Sekolah Teknik Elektro dan Informatika
Institut Teknologi Bandung
Bandung, Indonesia
yjhouma@gmail.com

Dr. Ir. Rinaldi Munir, M.T.
Sekolah Teknik Elektro dan Informatika
Institut Teknologi Bandung
Bandung, Indonesia
rinaldi@informatika.org

Abstract—Dalam memprediksi pergerakan pasar modal, yang menjadi perhatian utama adalah menentukan kapan waktu yang tepat untuk membeli, menjual, atau menahan suatu saham. Penelitian ini bertujuan untuk menghasilkan model yang mampu memprediksi pergerakan saham di kemudian hari dari suatu perusahaan. Hal ini dapat membantu investor untuk menentukan strategi investasi dengan lebih efisien. Pada penelitian ini solusi yang diajukan dibagi menjadi dua komponen, yaitu komponen praproses dan komponen prediksi. Praproses yang dilakukan adalah mengubah data harga historis menjadi matriks yang merepresentasikan candle chart. Untuk memprediksi pergerakan harga saham model yang digunakan adalah Convolutional Neural Network untuk time-series. Model dengan parameter terpilih memiliki akurasi rata-rata 54.35% dan rata-rata luas area di bawah ROC 0.5576.

Keywords—Pergerakan saham; time-series; convolutional neural network

I. PENDAHULUAN

Prediksi dalam dunia finansial, khususnya pasar modal merupakan salah satu area penelitian terpanas akhir-akhir ini dikarenakan aplikasi komersialnya [1]. Dalam memprediksi pergerakan pasar modal, yang menjadi perhatian utama adalah menentukan kapan waktu yang tepat untuk membeli, menjual, atau menahan suatu saham. Agar dapat memaksimalkan keuntungan seorang investor haruslah memprediksi dengan tepat kapan melakukan ketiga hal tersebut.

Metode paling umum yang digunakan untuk menganalisis pergerakan pasar modal umumnya dikelompokkan menjadi dua yaitu, analisis fundamental dan analisis teknikal [2] Analisis teknikal adalah aktivitas menganalisa suatu emiten di pasar modal berdasarkan data historis seperti harga dan jumlah transaksi. Sedangkan, analisis fundamental merupakan aktivitas menganalisa nilai fundamental, seperti kesehatan keuangan dari suatu emiten. Umumnya analisis-analisis ini masih dilakukan seorang investor secara manual, oleh sebab itu penelitian untuk memprediksi pergerakan harga di pasar modal banyak dilakukan. Tujuan utamanya adalah untuk mempermudah investor dalam merencanakan strategi investasi yang efisien. Untuk mencapai tujuan tersebut, algoritma yang mampu membantu investor untuk memprediksi pergerakan harga di pasar modal berdasarkan data-data historis dari suatu emiten dapat digunakan.

Untuk memprediksi pergerakan harga saham, salah satu kandidat algoritma yang dapat digunakan adalah pembelajaran mesin. Pembelajaran mesin adalah algoritma yang memproses sekumpulan data untuk membangun model yang memiliki nilai guna, misalnya, memiliki akurasi prediksi yang tinggi [3]. Sebelumnya sudah ada banyak penelitian terkait prediksi harga saham dengan menggunakan algoritma pembelajaran mesin [4,5,6].

Metode *deep-learning* adalah salah satu metode pembelajaran representasi, dengan berbagai tingkat representasi, yang didapat dengan menyusun modul sederhana namun *non-linear* yang masing-masing mengubah representasi pada satu tingkat (dimulai dengan *input*) menjadi representasi pada tingkat yang lebih tinggi [7]. Metode ini telah berhasil menjadi terobosan pada bidang-bidang seperti pengenalan suara, pengenalan objek visual, deteksi objek, dan banyak domain lainnya seperti penemuan obat dan genomik. Namun, karena arsitektur yang cukup rumit, metode ini memerlukan data dengan jumlah yang relatif besar dan kekuatan komputasi yang relatif tinggi.

Salah satu bentuk arsitektur dari *deep-learning* ini adalah *Convolutional Neural Network (CNN)*. CNN merupakan jaringan *feedforward* dimana arus informasi mengalir dalam satu arah saja, dari *input* ke *output*. Sama seperti *Artificial Neural Network (ANN)* yang terinspirasi dari proses biologis, demikian juga CNN.[8]. Topologi dari arsitektur ini bermacam-macam, namun secara umum arsitektur memiliki *convolution layer* dan *pooling layer*. Kedua layer yang membuat arsitektur CNN mampu mengekstraksi fitur-fitur dari masukkannya. Dalam beberapa penelitian arsitektur ini juga digunakan untuk data time series [9,10]. Data historis dari harga pasar modal dapat dimodelkan menjadi data time series.

Pada dasarnya melakukan prediksi saham menggunakan model pembelajaran mesin, baik *deep-learning* atau model lainnya, merupakan bagian dari analisis teknikal karena penggunaan data historis. Salah satu analisis teknikal yang sering digunakan seorang investor adalah analisis chart dimana investor mengambil keputusan berdasarkan bentuk dari harga historis suatu saham, namun analisis ini memerlukan intuisi dari investor tersebut untuk mengekstraksi informasi dari bentuk chart tersebut. *Deep-learning* khususnya CNN dikenal akan kemampuannya untuk mengekstraksi fitur dari masukan yang abstrak seperti gambar, teks, dan audio. Dikarenakan

kemampuan CNN tersebut maka model ini dianggap cocok untuk mengekstraksi fitur dari harga historis saham, yang sebelumnya hanya mengandalkan intuisi investor.

II. STUDI LITERATUR

A. Candle Chart Analysis

Dalam merepresentasikan nilai harga suatu saham grafik yang umum digunakan dinamakan candle chart, grafik ini dibuat berdasarkan harga saham tersebut dalam suatu rentan waktu, baik bulanan, harian, atau jam. Dalam candle chart informasi yang ditampilkan adalah harga terendah, harga tertinggi, harga pembukaan, dan harga penutupan dalam satu rentan waktu. Banyak analis teknikal yang menggunakan grafik ini sebagai landasan untuk memprediksi pergerakan harga.



GAMBAR I CANDLE CHART LQ45 DARI APLIKASI HOTS

Menurut Robert D. Edwards, W.H.C. Bassetti, dan John Magee [11], salah satu cara untuk melakukan analisis teknikal dapat melihat dari bentuk diagram yang merupakan representatif harga-harga dari suatu saham, atau disebut juga chart analysis. Karena data yang digunakan biasanya bertipe waktu/periode waktu dan harga dari saham, biasanya data periode akan ditentukan berdasarkan kebutuhan analisis. Analisis teknikal dengan melihat diagram merupakan cara yang digunakan untuk mendeteksi ketahanan harga dari suatu saham atau sebagai masukan untuk memprediksi harga saham pada hari/minggu tertentu. Analisa teknikal menggunakan diagram menjadi aktivitas yang penting dalam transaksi saham. Penelitian oleh Prado et al [12], menyatakan bahwa penggunaan diagram dalam analisis teknikal di secara statistik dapat membantu memprediksi harga saham secara signifikan.

B. Klasifikasi Time-Series (TSC)

Menurut salah satu penelitian [13], Definisi formal dari TSC adalah sebagai berikut:


- Definisi 1 sebuah *univariate time series* $X = [x_1, x_2, x_3, \dots, x_t]$ adalah sekumpulan nilai yang terurut berdasarkan waktu dengan panjang X sama dengan t .
- Definisi 2 *multivariate time series* dengan M dimensi, $X = [X_1, X_2, X_3, \dots, X_M]$ terdiri dari M *univariate time series* yang berbeda.
- Definisi 3 Sebuah dataset $D = \{(X_1, Y_1), (X_2, Y_2), \dots, (X_N, Y_N)\}$ adalah kumpulan *tuple* (X_i, Y_i) dimana X_i bisa merupakan *univariate* ataupun *multivariate time series* dengan Y_i merupakan label kelas dari time series bersangkutan

Dalam TSC akan dibentuk sebuah classifier dari dataset D untuk memetakan nilai input yang mungkin ke distribusi peluang dari kelas yang ada. Dikarenakan data yang digunakan, yaitu data historis saham maka permasalahan pada penelitian ini didefinisikan berdasarkan permasalahan ini, dimana klasifikasi yang digunakan adalah 1 untuk harga naik dan 0 untuk harga turun.

C. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu topologi dari *deep neural network*. CNN umumnya digunakan untuk dataset yang berupa gambar, seperti pada dataset *ImageNet* [14] dan pengenalan wajah [15]. Namun, belakangan juga berkembang penelitian penggunaan CNN untuk klasifikasi *multivariate time series* [10]. Yang membedakan CNN dari *Neural Network* pada umumnya adalah adanya dua *layer* khusus, yaitu *convolution layer* dan *pooling layer*. Kedua *layer* ini berfungsi untuk mengekstraksi fitur yang dianggap penting dari matrix masukannya.


Convolutional layers berfungsi untuk mengekstraksi fitur dari masukan dengan operasi konvolusi. Operasi konvolusi dilakukan dengan melakukan menjumlahkan hasil perkalian *element-wise* dari matriks filter F dengan ukuran $n \times n$ dengan sebuah region dari input, operasi ini dilakukan berulang hingga semua region telah tercakup. Hasil dari operasi konvolusi ini berupa matriks yang disebut dengan *feature map*.



GAMBAR II CONVOLUTION LAYER [16]

Tujuan dari *pooling layer* adalah mengurangi *spatial resolution* dari *feature map* yang sebelumnya didapatkan dari *convolution layer*. Untuk melakukan hal tersebut, *layer* ini melakukan operasi yang disebut dengan *spatial pooling*. Terdapat dua operasi *spatial pooling* yang umum digunakan yaitu *average pooling*, dan *maximum pooling*. Matriks dari

feature map akan dibagi-bagi dengan ukuran $m \times m$, lalu dari tiap bagian tersebut akan diambil nilai terbesar sebagai fitur akhir untuk *maximum pooling*, sedangkan untuk *average pooling* yang menjadi fitur akhir adalah nilai rata-rata dari seluruh titik yang ada pada bagian tersebut.




GAMBAR III POOLING LAYER [17]

D. Convolutional Neural Network untuk Time-series

Dalam sebuah penelitian oleh Zhao et al [10], diajarkan arsitektur CNN yang digunakan untuk melakukan *time-series classification*. Adapun arsitektur yang diajarkan terdiri dari *layer-layer* berikut:

- *Input Layer* yang berukuran $N \times k$, dimana k merupakan jumlah data *time-series univariate* yang menjadi masukan dan N merupakan panjang dari data *time-series* tersebut.
- *Convolutional Layer* dengan jumlah filter sebanyak m dan ukuran filter-filter tersebut $l \times k$, dimana k merupakan jumlah data *time-series univariate* dari input layer dan l merupakan panjang dari filter tersebut. Nilai dari m dan l merupakan parameter yang dapat diatur.
- *Pooling Layer* yang sama dengan *pooling layer* pada arsitektur CNN pada umumnya, antara *max pooling* atau *average pooling*
- *Feature Layer* dimana hasil semua operasi *convolution* dan *pooling* terhadap data *time-series multivariate* disambung menjadi sebuah *time-series univariate* baru yang akan menjadi input untuk *fully connected layer*.
- *Output Layer* merupakan layer yang memiliki n buah *neuron*, dimana n jumlah kelas yang ada untuk *time-series classification* terkait.



GAMBAR IV CNN UNTUK MULTIVARIATE TIME-SERIES [10]

Dikarenakan data yang digunakan pada penelitian ini merupakan data *multivariate time series*, yaitu semua informasi mengenai harga saham, model ini digunakan untuk mengembangkan solusi pada penelitian ini. Parameter yang akan dicari untuk menemukan model terbaik adalah parameter ukuran filter seperti yang dijelaskan.

III. ANALISIS DAN RANCANGAN SOLUSI

A. Analisa Masalah dan Solusi

Masalah utama dari penelitian ini adalah bagaimana membangun model klasifikasi untuk memprediksi pergerakan harga suatu saham di pasar modal. Data historis dari pasar modal dapat digunakan untuk membangun model ini. Patel, Shah, Thakkar, dan Kotheca [5] membandingkan empat buah model untuk melakukan prediksi pergerakan harga saham salah satu diantaranya adalah ANN. Sedangkan Sheng Chen dan Hoxiang He [19] mencoba pendekatan yang berbeda yaitu menggunakan arsitektur CNN. Namun, untuk kedua penelitian ini data transformasi dan praproses tidak berusaha menirukan apa yang dilakukan oleh seorang investor teknikal dalam melakukan prediksi. Agar model yang dibangun mendekati apa yang dilakukan investor teknikal profesional diperlukan praproses yang merepresentasikan apa yang dilihat oleh investor tersebut dan juga model yang mampu mempelajari representasi dari data tersebut sehingga menyerupai apa yang dilakukan seorang investor.

Dari analisis masalah diatas, solusi yang dapat menjawab permasalahan yang adalah model klasifikasi dengan arsitektur CNN. CNN digunakan karena tujuan dari model yang akan digunakan adalah meniru apa yang dilakukan analisis teknikal dalam melihat *candle chart*. Dalam melihat *candle chart*, seorang analis teknikal melihat interaksi antara bagian dari *chart* tersebut, dan *convolution layer* dan *pooling layer* dari CNN mampu mengekstraksi fitur dari sebuah data. Sedangkan praproses yang perlu dilakukan adalah mengubah data informasi harga saham yang berupa *multivariate time-series* menjadi matrix dengan informasi yang menyerupai informasi pada grafik yang dianalisis seorang investor teknikal. Selain itu fungsi konvolusi pada CNN mampu mengekstraksi fitur dari *input* yang berupa *multivariate time-series* sehingga interaksi antar variable diharapkan dapat ditemukan oleh model CNN.

B. Input

Input untuk model yang akan digunakan adalah data historis harga saham. Data historis sebuah saham mengandung empat buah informasi. Pertama adalah *open*, yaitu informasi harga ketika pembukaan pasar pada hari tersebut. Kedua, *close*, yaitu informasi harga di akhir harga ketika pasar ditutup pada hari tersebut. Ketiga, *high*, yaitu harga tertinggi selama pasar beroperasi pada hari tersebut. Terakhir, *low*, yaitu harga terendah selama pasar beroperasi pada hari tersebut.

Keempat informasi ini yang divisualisasikan menjadi grafik yang disebut dengan *candle chart*. Grafik ini yang kemudian dianalisis oleh investor teknikal untuk ditentukan keputusan beli atau jual. Untuk meniru hal ini data yang diperoleh harus praproses terlebih dahulu. Praproses yang dilakukan harus mampu merepresentasikan apa yang dilihat oleh seorang analis teknikal agar model yang dibangun dapat menyerupai apa yang dilakukan analis-analis tersebut.

C. Praproses Input

Praproses yang dilakukan adalah memotong data masukan yang merupakan data *time-series* menjadi beberapa bagian masing-masing sepanjang n , untuk penelitian ini $n=20$, yang berarti data yang akan dilihat oleh model adalah data harga saham n hari ke belakang. Kemudian potongan-potongan data tersebut diubah menjadi matriks yang masing-masing barisnya merupakan informasi yang terdapat pada data harga saham tersebut.

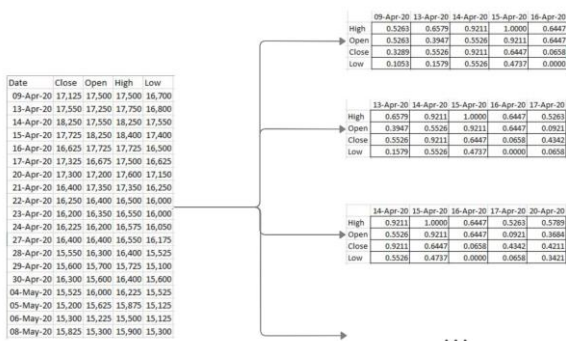
$$P = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1n} \\ P_{21} & P_{22} & \dots & P_{2n} \\ P_{31} & P_{32} & \dots & P_{3n} \\ P_{41} & P_{42} & \dots & P_{4n} \end{bmatrix}$$

GAMBAR V ILUSTRASI REPRESENTASI MATRIKS INPUT

Tiap-tiap matriks yang menjadi *input* kemudian di normalisasi dengan formula:

$$P_{ij} - \min(P) / (\max(P) - \min(P)) \quad (1)$$

Matriks yang sudah dinormalisasi ini akan menjadi *input* yang digunakan untuk membangun model CNN.



GAMBAR VI ILUSTRASI PRAPROSES DENGAN N=5

D. Output

Seorang analis teknikal akan melihat *candle chart* dan melakukan analisis untuk mengambil keputusan beli atau jual – apakah saham tersebut naik atau turun. Model yang akan dibangun akan menirukan cara seorang analis teknikal dalam melakukan analisis, sehingga keluaran dari model ini akan sama dengan apa yang dilakukan analis teknikal. Dengan demikian keluaran dari model yang akan dibangun berupa hasil klasifikasi bahwa saham tersebut akan naik atau turun, masing-masing akan direpresentasikan dengan angka 1 dan 0, di kemudian hari tanpa memperdulikan seberapa besar magnitude dari naik atau turunnya harga saham tersebut.

IV. EKSPERIMEN

Tujuan dari eksperimen ini adalah untuk mengetahui apakah pra-proses yang dilakukan dapat memberikan hasil yang lebih baik untuk memprediksi pergerakan pasar modal dan juga untuk menentukan arsitektur CNN seperti apa yang lebih baik dalam performa prediksi.

A. Data Eksperimen

Data eksperimen yang digunakan adalah harga harian dari saham yang terdaftar pada KOSPI 200 dari tahun 2002 hingga 2012, sama seperti yang dilakukan oleh Wang dan Choi [20]. Data ini terdiri dari 200 perusahaan paling aktif dalam bursa saham Korea Selatan. Kemudian akan dibangun variable *target* dari data ini yang menunjukkan apakah harga akan naik pada hari berikutnya. Penggunaan data ini dilakukan agar hasil penelitian ini dapat dibandingkan dengan penelitian tersebut.

Data ini akan dibagi menjadi data *training* dan *test*. Karena permasalahan ini merupakan permasalahan *time-series* maka pembagian data *train* dan *test* dilakukan berdasarkan waktu. *Training* dan *testing* akan dilakukan berulang kali dengan menggunakan data yang dikelompokkan berdasarkan tahun. Skema penggunaan data *train* dan *test* seperti tabel dibawah ini.

TABEL I PEMBAGIAN DATA TEST DAN TRAIN

Iterasi	Tahun Train	Tahun Test
1	2002 - 2005	2006
2	2003 - 2006	2007
3	2004 - 2007	2008
4	2005 - 2008	2009
5	2006 - 2009	2010
6	2007 - 2010	2011
7	2008 - 2011	2012

B. Skenario Eksperimen

Eksperimen dilakukan untuk menentukan arsitektur CNN *time-series* yang terbaik untuk memprediksi pergerakan harga saham. Model dipilih dengan cara membandingkan performa dari ketiga model dengan parameter berbeda yang dibangun. Berikut adalah kandidat parameter yang akan diuji, parameter berkelipatan lima karena satu minggu transaksi dilakukan dalam lima hari.

TABEL II PARAMETER YANG AKAN DIUJI

No.	Ukuran Convolution Filter 1	Ukuran Pooling 1	Ukuran Convolution Filter 2	Ukuran Pooling 2
1	5	5	5	5
2	10	5	10	5
3	15	10	10	5

Adapun skenario eksperimen yang akan dilakukan seperti berikut.

- Membangun 3 model dengan parameter yang ditentukan
- Melatih model-model dengan data empat tahun dan mengujinya dengan data tahun berikutnya. Masing-masing model akan dilatih dengan menggunakan 100 *epoch* dan model yang terpilih adalah model dengan nilai *validation roc auc* tertinggi.
- Selanjutnya mengulangi langkah pertama hingga kedua dengan menggunakan data tahun berikutnya
- Membandingkan hasil evaluasi secara keseluruhan dan memilih model yang memiliki performa terbaik sebagai model terpilih.

Selain dengan melakukan eksperimen pada parameter ukuran filter dari arsitektur CNN yang diajukan, akan dilakukan pula eksperimen pada parameter lain yaitu penambahan dan pengurangan layer dari parameter terpilih, yaitu mengurangi dan menambahkan masing-masing satu *convolution layer* dan *pooling layer*. Eksperimen dengan model pembanding juga akan dilakukan yaitu dengan tiga buah model *Multi-Layer Perceptron*, yang masing-masing memiliki arsitektur (1) satu *hidden layer* dengan 64 *node*, (2) satu *hidden layer* dengan 32 *node*, dan (3) dua *hidden layer* dengan masing-masing *node* berukuran 64 dan 32. Eksperimen-eksperimen ini akan mengikuti skenario yang sama dengan penyelesaian parameter ukuran filter pada arsitektur CNN yang digunakan.

C. Hasil Eksperimen

TABEL III HASIL EKSPERIMEN PARAMETER CNN *TIME-SERIES*

Iterasi	Parameter	Parameter 1	Parameter 2	Parameter 3
1	Akurasi	0.5402	0.5392	0.5368
	ROC AUC	0.5509	0.5508	0.5516
2	Akurasi	0.5304	0.5301	0.5251
	ROC AUC	0.5347	0.5343	0.5311

3	Akurasi	0.5521	0.5552	0.5519
	ROC AUC	0.5688	0.5658	0.5586
4	Akurasi	0.5423	0.5393	0.5248
	ROC AUC	0.5598	0.5514	0.5375
5	Akurasi	0.5435	0.5387	0.5371
	ROC AUC	0.5589	0.5536	0.549
6	Akurasi	0.5463	0.5398	0.5336
	ROC AUC	0.5615	0.5572	0.5493
7	Akurasi	0.5498	0.5469	0.5438
	ROC AUC	0.5687	0.5632	0.5641

Dari hasil eksperimen diatas dapat dibandingkan hasil dari model dengan parameter berbeda yang dilatih tiap iterasi eksperimen. Dapat disimpulkan bahwa parameter terbaik dari antara ketiga parameter ini adalah parameter 1, yaitu model CNN dengan ukuran filter 5 atau model yang melihat data mingguan. Dari tabel dapat dilihat bahwa parameter 1 memiliki performa yang lebih baik untuk Akurasi dan ROC AUC pada tiap iterasi kecuali ROC AUC iterasi pertama dan akurasi iterasi ketiga

TABEL IV HASIL EKSPERIMEN MODEL DAN PARAMETER LAIN

Model	Iterasi	1	2	3	4	5	6	7
CNN Parameter Terpilih	ROC AUC	0.5509	0.5347	0.5688	0.5598	0.5589	0.5615	0.5687
	Akurasi	54.02%	53.04%	55.21%	54.23%	54.35%	54.63%	54.98%
MLP 1	ROC AUC	0.5632	0.5603	0.58	0.5537	0.5554	0.5521	0.5627
	Akurasi	54.66%	54.10%	55.94%	53.89%	54.12%	53.50%	54.61%
MLP 2	ROC AUC	0.562	0.5657	0.5727	0.5496	0.5547	0.5535	0.5632
	Akurasi	54.70%	54.42%	55.35%	53.51%	54.11%	53.86%	54.64%
MLP 3	ROC AUC	0.5619	0.5606	0.5821	0.5523	0.546	0.5489	0.5641
	Akurasi	54.47%	54.37%	56.19%	53.55%	53.18%	53.37%	54.37%
Model	Iterasi	1	2	3	4	5	6	7
CNN Satu Layer	ROC AUC	0.5775	0.5664	0.5905	0.5598	0.5505	0.56	0.5734
	Akurasi	55.04%	54.35%	56.26%	54.41%	53.25%	54.15%	55.11%
CNN Tiga Layer	ROC AUC	0.5439	0.5314	0.5582	0.5168	0.5249	0.53	0.547
	Akurasi	54.39%	53.14%	55.82%	51.68%	52.49%	53.00%	54.70%

Hasil eksperimen dengan menggunakan parameter lain, yaitu jumlah layer pada arsitektur CNN dan juga model pembanding lain yaitu *Multi Layer Perceptron* (MLP) seperti yang dijelaskan pada IV.1.3, tertera pada tabel IV.3. Dilihat

dari hasil perbandingan CNN *time-series* dengan arsitektur satu pasang *layer* (*convolution layer* dan *pooling layer*) menjadi hasil terbaik untuk kebanyakan iterasi, kecuali pada iterasi 5 dan 6 dimana model CNN yang diajukan dengan parameter terpilih.

TABEL V PERBANDINGAN HASIL DENGAN PENELITIAN WANG

Iterasi	Model Hasil Eksperimen	Eksperimen Wang dan Choi (Model Terbaik)
1	54.02%	75.90%
2	53.04%	56.68%
3	55.21%	66.26%
4	54.23%	59.43%
5	54.35%	59.68%
6	54.63%	69.75%
7	54.98%	61.29%

Tabel V memperlihatkan hasil perbandingan model CNN dengan parameter hasil eksperimen dengan hasil terbaik dari penelitian terkait. Dari tabel V dapat dilihat bahwa prediksi pergerakan saham dengan menggunakan CNN dan metode pra-proses yang digunakan tidak lebih baik dari penelitian sebelumnya.

D. Analisis Hasil Eksperimen

Berdasarkan Tabel V dapat dilihat bahwa hasil akurasi yang lebih rendah untuk setiap iterasi dibandingkan dengan eksperimen yang dilakukan Wang dan Choi [20]. Dua kemungkinan yang menyebabkan hal ini adalah penggunaan data tambahan oleh Wang dan juga arsitektur CNN yang digunakan tidak dapat menangkap pola yang terdapat pada data input.

Data yang digunakan oleh Wang dan Choi bukan hanya harga historis, dalam eksperimen mereka juga menambahkan dua variabel eksternal sebagai input dari model yang mereka bangun. Pertama indeks S&P 500, yaitu salah satu indeks saham yang ada di Amerika Serikat, menurut Phillip Brzenk [21] indeks ini memiliki pengaruh terhadap pasar global. Variabel eksternal kedua adalah nilai tukar Dollar Amerika, dimana nilai tukar terhadap dollar amerika dapat menjadi indikator ekonomi suatu negara. Kedua variabel eksternal yang digunakan Wang dan Choi ini dapat memperkuat kemampuan prediksi model yang mereka gunakan.

Arsitektur CNN yang digunakan pada eksperimen merupakan arsitektur CNN untuk *time series* sederhana yang diajukan oleh Zhao, Lu, Chen, Liu, dan Wu [18]. Karena arsitektur yang diajukan tidak dirancang secara khusus untuk permasalahan prediksi saham, arsitektur yang digunakan tidak dapat mengekstraksi pola dari data dengan baik. Menurut Segios Theodoridis [22] salah satu parameter yang mempengaruhi performa model *neural network* adalah ukurannya, dalam kasus ini jumlah *hidden layer*, dimana bila arsitektur model terlalu besar atau terlalu kecil dapat memberikan performa yang tidak baik.

Melihat Tabel IV yaitu hasil eksperimen dengan membandingkan dengan parameter lain dari arsitektur CNN,

dapat dilihat bahwa arsitektur yang lebih kecil memiliki performa rata-rata yang lebih baik dari arsitektur yang diajukan dengan parameter yang terpilih. Hal ini menunjukkan kemungkinan data input yang digunakan terlalu kecil untuk digunakan pada arsitektur CNN dengan *layer* berlapis-lapis, sehingga model yang dibangun tidak dapat dengan baik mengekstraksi pola dari data input tersebut.

Penggunaan input dengan ukuran kecil menimbulkan permasalahan tersendiri untuk model CNN [22]. Input matriks yang terlalu kecil tidak menyimpan informasi yang cukup untuk diekstraksi oleh fungsi konvolusi dan *pooling* dari arsitektur CNN. Pada kasus ini, input data yang digunakan terbilang kecil, sehingga model ini tidak mampu mengekstraksi fitur dari matriks input dan memberikan performa yang tidak baik.

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Kesimpulan yang dapat diambil berdasarkan analisis dari hasil eksperimen dan pengujian adalah sebagai berikut.

- Pengembangan Model CNN yang diajukan Zhao, Lu, Chen, Liu, dan Wu (2017) digunakan untuk melakukan prediksi pergerakan harga saham, dengan melakukan pra-proses mengubah data historis harga saham menjadi matriks *input* untuk CNN.
- Dengan skenario eksperimen dengan tujuh iterasi, diperoleh bahwa parameter model CNN untuk *time series* yang digunakan untuk prediksi pergerakan saham (naik/turun) adalah ukuran *convolution* pertama 5, ukuran *pooling* layer pertama 5, ukuran *convolution* kedua 5, dan ukuran *pooling* layer kedua 5. Parameter terpilih menghasilkan rata-rata akurasi 54.35%
- Model prediksi pergerakan harga saham yang dihasilkan dengan eksperimen belum memiliki kinerja yang lebih baik daripada hasil eksperimen terkait, yaitu eksperimen Wang dan Choi (2013). Perbedaan hasil ini dapat terjadi karena dua hal yaitu, penggunaan data eksternal oleh Wang dan Choi dan Arsitektur CNN yang sederhana tidak mampu menggeneralisir pola pada data.
- Ukuran input yang terbilang kecil mengakibatkan model CNN yang digunakan tidak mampu mengekstraksi fitur dari input yang diberikan, sehingga penggunaan CNN standard dianggap kurang cocok untuk permasalahan seperti ini.

B. Saran

Berikut adalah saran yang dapat dilakukan

- Menggunakan sampel data yang lebih besar untuk pembangunan dan evaluasi model prediksi pergerakan harga saham. Hal ini dilakukan agar model yang digunakan mampu menggeneralisasi pola yang ditemukan dengan lebih baik. Misalnya dengan menambahkan faktor volume transaksi.

- Menggunakan arsitektur model yang berbeda untuk melakukan prediksi, agar dapat menggeneralisasi data yang abstrak dapat digunakan arsitektur model yang berbeda, misalnya dengan mengubah jumlah layer konvolusi dan *hidden layer*.

DAFTAR PUSTAKA

- [1] Majhi, Ritanjah, G. Panda, G. Sahoo, P. K. Dash and D. P. Das, "Stock market prediction of S&P 500 and DJIA using bacterial foraging optimization technique," *IEEE congress on evolutionary computation*, pp. 2569-2575, 2007.
- [2] T. Oberlechner, "Importance of technical and fundamental analysis in the European foreign exchange market," *International Journal of Finance & Economics* 6, no. 1, pp. 81-93, 2001.
- [3] E. Alpaydin, Introduction to machine learning, MIT Press, 2020.
- [4] R. Choudhry and K. Garg, "A hybrid machine learning system for stock market forecasting," *World Academy of Science, Engineering and Technology*, pp. 315-318, 2008.
- [5] J. Patel, S. Shah, P. Thakkar and K. Kotecha, "Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques," *Expert Systems with Applications*, pp. 259-268, 2015.
- [6] B. Qian and K. Rasheed, "Stock market prediction with multiple classifiers," *Applied Intelligence*, pp. 25-33, 2007.
- [7] Y. LeCun, Y. Bengio and G. Hinton, "Deep learning," *nature* 521, no. 7553, pp. 436-444, 2015.
- [8] W. Rawat and Z. Wang, "Deep convolutional neural networks for image classification: A comprehensive review," *Neural computation* 29, no. 9, pp. 2352-2449, 2017.
- [9] Z. Cui, W. Chen and Y. Chen, "Multi-scale convolutional neural networks for time series classification," *arXiv preprint arXiv:1603.06995*, 2016.
- [10] Y. Zheng, Q. Liu, E. Chen, Y. Ge and J. L. Zhao, "Time series classification using multi-channels deep convolutional neural networks," *International Conference on Web-Age Information Management*, pp. 298-310, 2014.
- [11] R. D. Edwards, W. H. C. Bassetti and J. Magee, Technical analysis of stock trends, CRC Press, 2007.
- [12] H. d. Prado, E. Ferneda, L. C. Morais, A. J. Luiz and E. Matsura, "On the effectiveness of candlestick chart analysis for the Brazilian stock market," *Procedia Computer Science* 22, pp. 1136-1145, 2013.
- [13] Fawaz, H. Ismail, G. Forestier, J. Weber, L. Idoumghar and P.-A. Muller, "Deep learning for time series classification: a review," *Data Mining and Knowledge Discovery* 33, no. 4, pp. 917-963, 2019.
- [14] Krizhevsky, Alex, I. Sutskever and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, pp. 1097-1105, 2012.
- [15] Lawrence, Steve, C. L. Giles, A. C. Tsoi and A. D. Back, "Face recognition: A convolutional neural-network approach," *IEEE transactions on neural networks* 8, no. 1, pp. 98-113, 1997.
- [16] R. Hachilif, R. Baghdadi and F. Benhamida, "Graduation Thesis Implementing and Optimizing Neural Networks using Tiramisu," 2019.
- [17] B. Zhao, H. Lu, S. Chen, J. Liu and D. Wu, "Convolutional neural networks for time series classification," *Journal of Systems Engineering and Electronics* 28, no. 1, pp. 162-169, 2017.
- [18] S. Chen and H. He, "Stock Prediction Using Convolutional Neural Network," in *IOP Conference Series: Materials Science and Engineering*, 2018.
- [19] Y. Wang and I.-C. Choi, "Market index and stock price direction prediction using machine learning techniques: an empirical study on the KOSPI and HSI," *arXiv preprint arXiv:1309.7119*, 2013.
- [20] P. Brzenk, "The Impact of the Global Economy on The S&P 500," S&P Global, 2018.
- [21] S. Theodoridis, Machine Learning: A Bayesian and Optimization Perspective, Academic press, 2015.
- [22] T. Truong, V. Nguyen and M. Tran, "Lightweight Deep Convolutional Network for Tiny Object Recognition," *ICPRAM*, pp. 675-682, 2018.