

Model Hybrid Menggunakan Dekomposisi-Neural Network Untuk Data Indeks Harga Saham Gabungan

Imelda Saluza¹⁾, Dewi Sartika²⁾, Ensiwi Munarsih³⁾

¹⁾ Program Studi Sistem Informasi, Universitas Indo Global Mandiri

²⁾ Program Studi Teknik Informatika, Universitas Indo Global Mandiri

³⁾ Program Studi Farmasi, Sekolah Tinggi Ilmu Farmasi Bhakti Pertiwi Palembang

Jalan Jendral Sudirman No. 629 KM 4 Palembang 30129

Email : imeldasaluza@uigm.ac.id¹⁾, dewi.sartika@uigm.ac.id²⁾, ensiwimunarsih@gmail.com³⁾

ABSTRACT

The development of Covid-19 has worsened the economy not only nationally but also globally. Since its spread, the price movement of the Jakarta Composite Index (IHSG) has continued to be volatile. JCI price volatility shows risk and uncertainty in investing. Volatility is used as a barometer to determine portfolio management strategies for financial actors. Therefore, financial actors should find a strategy to be able to predict JCI price movements to reduce risks and gain profits. One way that can be done is to predict the JCI price as a reference in investing. This study uses a hybrid model between the decomposition model and the Neural Network (NN) in predicting JCI price volatility. The decomposition uses two approaches, namely additive and multiplicative, the two approaches will then be combined with NN and the NN algorithm used is Feed Forward Neural Network (FFNN) where the results of the decomposition in the form of seasonal, trend, and random data are used as input in the FFNN architecture. The FFNN architecture in this study differs from the hidden layer nodes and the epochs used. Furthermore, the prediction results from the model are compared with a single NN. The performance of each architecture will be measured using the Mean Absolute Error (MAE) and Mean Square Error (MSE). The results show that the hidden layer with more nodes can provide good performance while the epoch used provides good performance depending on the learning process carried out. The prediction results using the hybrid model can outperform the performance of a single NN.

Keywords : time series, volatilitas, studi perbandingan, kecerdasan buatan, statistik.

ABSTRAK

Perkembangan covid-19 telah memperburuk perekonomian tidak hanya Nasional bahkan global. Sejak penyebarannya pergerakan harga Indeks Harga Saham Gabungan (IHSG) terus menjadi volatil. Volatilitas harga IHSG menunjukkan resiko dan ketidakpastian dalam berinvestasi. Bahkan volatilitas dijadikan barometer untuk menentukan strategi manajemen portofolio bagi para pelaku keuangan. Karenanya pelaku keuangan hendaknya menemukan strategi untuk dapat memprediksi pergerakan harga IHSG agar dapat mengurangi resiko dan mendapatkan keuntungan. Salah satu cara yang dapat dilakukan adalah dengan memprediksi harga IHSG sebagai acuan dalam berinvestasi. Penelitian ini menggunakan model *hybrid* antara model dekomposisi dan Neural Network (NN) dalam memprediksi volatilitas harga IHSG. Dekomposisi menggunakan dua pendekatan yaitu *additive* dan *multiplicative*, kedua pendekatan tersebut selanjutnya akan digabungkan dengan NN dan algoritma NN yang digunakan adalah *Feed Forward Neural Network* (FFNN) dimana hasil dekomposisi berupa data musiman, trend dan random dijadikan inputan dalam arsitektur FFNN. Arsitektur FFNN pada penelitian ini dilakukan perbedaan terhadap node lapisan tersembunyi dan epoch yang digunakan. Selanjutnya hasil prediksi dari model tersebut dibandingkan dengan NN tunggal. Kinerja dari masing-masing arsitektur akan diukur menggunakan *Mean Absolute Error* (MAE) dan *Mean Square Error* (MSE). Hasil penelitian menunjukkan bahwa lapisan tersembunyi dengan node yang lebih banyak mampu memberikan kinerja yang baik sedangkan untuk epoch yang digunakan memberikan kinerja yang baik tergantung dengan proses pembelajaran yang dilakukan. Hasil prediksi menggunakan model *hybrid* mampu mengungguli kinerja dari NN tunggal.

Kata Kunci : time series, volatilitas, studi perbandingan, kecerdasan buatan, statistik.



Article History

Received : 10/05/2022
Revised : 24/07/2022
Accepted : 08/09/2022
Online : 30/12/2022



This is an open access article under the
CC BY-SA 4.0 License

1. Pendahuluan

Berkembangnya covid-19 memberikan dampak besar yang dapat memperburuk kondisi perekonomian global (Gao et al., 2022) dan menyebabkan resesi parah bahkan terjadinya depresi (Z. Li et al., 2022), bahkan memberikan dampak jangka panjang terhadap globalisasi. Dampak besar ini juga berimbas terhadap perekonomian Indonesia, hal ini ditunjukkan dengan terjadinya perlambatan pertumbuhan ekonomi pada tahun 2020 (dimana angka pertumbuhan tahun 2019 sebesar 5,02% menjadi 2,97%) (T. Ahmad, 2022) dan penurunan perekonomian yang signifikan pada tahun 2019 (Hanoatubun, 2020). Bahkan usaha yang dilakukan berbagai pemerintah di negara dengan mengeluarkan kebijakan untuk mengatasi penyebaran covid-19 dapat menyebabkan terjadinya permasalahan trade off antara penurunan perekonomian dengan banyaknya korban akibat covid-19, untuk itu di butuhkan kesehatan keselamatan kerja agar terhindar covid-19 (Heryati et al., 2019).

Covid-19 menyebabkan terjadinya volatilitas pada pasar saham (Z. Li et al., 2022), volatilitas ini terjadi di banyak negara seperti Amerika, China, Eropa bahkan Indonesia. Banyak penelitian yang telah menjelaskan adanya volatilitas terhadap saham. Antara lain (Chowdhury et al., 2022) melakukan penelitian terhadap pasar saham Amerika Serikat (AS) dari tanggal 24 Februari sampai Maret 2020 dalam 22 hari perdagangan, hasil penelitian menunjukkan bahwa terdapat 18 kali lonjakan pasar yang terjadi dan ini merupakan lompatan tertinggi yang pernah terjadi dalam periode perdagangan sama yang terjadi di AS. (E. Ahmad et al., 2020) meneliti dampak covid-19 pada bursa saham dan volatilitas saham di Pakistan, penelitian ini menggunakan data indeks bursa saham sebanyak 25 hari di bulan Maret di tahun 2020 dan hasilnya menunjukkan bahwa pemulihan penyakit berkorelasi positif terhadap indeks bursa sementara dan korban akibat covid-19 berkorelasi negatif terhadap harga saham dengan kata lain semakin banyak korban kematian dari covid-19 maka semakin tak menentu pergerakan volatilitas saham.

Volatilitas merupakan salah satu barometer resiko keuangan dan ketidakpastian keuangan. Volatilitas sangat digunakan untuk mengukur ketidakpastian dalam berinvestasi pada aset keuangan dan menjadi acuan bagi pelaku ekonomi (regulator pada industri keuangan, investor individu, manajer reksa dana dan pembuat kebijakan). Pergerakan volatilitas pada pasar keuangan merupakan fenomena normal namun jika osilasi harga bergerak sangat tajam dan curam akan menjadi permasalahan besar bagi para pelaku ekonomi (W. Li et al., 2022). Kinerja pasar keuangan yang tidak konsisten menciptakan kondisi keraguan dan menyulitkan bagi pelaku ekonomi untuk dapat memprediksi pasar. Volatilitas yang tinggi juga dapat menyebabkan adanya keuntungan bahkan kerugian yang besar bagi pelaku ekonomi.

Banyak pelaku ekonomi mengalami keterkejutan dari ketidakstabilan harga dari volatilitas harga saham akibat

terjadinya pandemi covid-19 yang menyebabkan mereka harus mampu mengadopsi strategi-strategi baru untuk mendukung keputusan yang baik (Heryati et al., 2021) dalam berinvestasi sehingga dapat meningkatkan keuntungan dan mengurangi resiko investasi. Temuan empiris dari penelitian (Moslehpour et al., 2022) menunjukkan bahwa covid-19 yang meluas secara global menyebabkan pergerakan resiko volatilitas di seluruh pasar saham; (Chowdhury et al., 2022) dalam penelitiannya menyatakan pasar saham sangat sensitif terhadap covid-19. Estimasi volatilitas yang akurat sangat penting untuk dilakukan dalam melakukan manajemen resiko. Pelaku ekonomi sangat antusias untuk mempelajari volatilitas sehingga dapat menerapkan pengetahuan yang dimiliki agar dapat memperoleh keuntungan yang besar dan memperkecil resiko yang akan terjadi. Memprediksi volatilitas merupakan faktor kunci untuk dianalisis dalam mengambil keputusan keuangan. Salah satunya dengan menganalisis persistensi volatilitas (Christianti, 2018).

Covid-19 saat ini belum dapat dikatakan berakhir namun sudah mengalami penurunan yang cukup tinggi dimana pada februari 2022 kasus covid-19 di Indonesia masih dalam angka tertinggi yaitu 59.384 kasus baru sedangkan di bulan November 4.877 kasus baru (google berita, n.d.). Penurunan kasus baru covid-19 membawa kebijakan baru dari pemerintah Indonesia untuk dapat melepaskan masker di outdoor yang dinyatakan oleh Presiden Republik Indonesia pada tanggal 17 Mei 2022, dengan adanya kebijakan ini maka aktivitas di luar rumah sudah dapat dilakukan seperti biasa seperti sedia kala sebelum terjadinya pandemi.

Kebijakan baru yang dikeluarkan pemerintah Indonesia diharapkan dapat memperbaiki perekonomian Indonesia, khususnya Indeks Harga Saham di Indonesia (IHSG). IHSG sejatinya merupakan tolak ukur kinerja portofolio, sebagai tempat untuk melihat pertumbuhan pasar serta sebagai penanda pergerakan pasar bagi pelaku ekonomi. Banyak penelitian yang telah dilakukan dalam memprediksi volatilitas IHSG selama pandemi, dan hasil penelitian menyatakan bahwa harga IHSG sangat berfluktuatif selama pandemi covid-19 sehingga berbagai metode prediksi digunakan untuk mengetahui pergerakan IHSG seperti (Gunawan & Astika, 2022) menggunakan model statistik Autoregressive Integrated Moving Average (ARIMA) untuk memprediksi; (Andhika Viadinugroho & Rosadi, 2021) menggunakan kecerdasan buatan yaitu model Long Short-Term Memory (LSTM) Neural Network untuk memprediksi IHSG selama covid-19.

Berbagai macam model telah digunakan untuk melakukan prediksi. Model prediksi tersebut dikategorikan menjadi model statistik, model data mining untuk menentukan prediksi (Heryati & Herdiansyah, 2020), kecerdasan buatan dan hybrid. Penggunaan model prediksi statistik, seperti ARIMA, dekomposisi, dan sebagainya dapat menunjukkan kinerja yang baik jika data yang digunakan merupakan data linear, namun ketika data banyak mengalami fluktuasi volatilitas maka model yang dapat digunakan adalah

model pada kecerdasan buatan seperti fuzzy, neural network, LSTM dan sebagainya. Namun keuntungan dari kedua model dalam menangkap linearitas dan non linearitas data time series akan sangat baik digunakan jika kedua model tersebut digabungkan untuk menyelesaikan permasalahan data yang berfluktuatif. Karena peneliti ini akan menggunakan model hybrid antara dalam proses prediksi data IHSG setelah pernyataan untuk membuka masker di outdoor. Penelitian ini akan melihat lonjakan IHSG yang terjadi kemudian memprediksi pergerakan volatilitas tersebut.

2. Pembahasan

Indeks Harga Saham Gabungan atau disingkat IHSG merupakan satuan ukuran yang digunakan untuk mengetahui kesehatan perusahaan-perusahaan yang terdaftar di Bursa Efek Indonesia (BEI) (Tjandrasa & Sutjiati, 2016). Indeks ini mencakup keseluruhan pergerakan harga saham biasa dan saham preferen yang tercatat pada BEI. (Insmanthono, 2003) mengungkapkan bahwa IHSG adalah indikator pasar saham yang dihitung dengan cara merata-ratakan saham namun sampel yang digunakan lebih luas. Dalam menghitungnya digunakan formula berikut (Robiyanto, 2018):

$$IHSG = \frac{\sum(P_s \times S_s)}{\sum(P_{dasar} \times S_s)} \dots (1)$$

dimana:

- IHSG* : Indeks Harga Saham Gabungan
- P_s* : Harga saham
- S_s* : Kejadian saat ini
- P_{dasar}* : Harga saham dasar

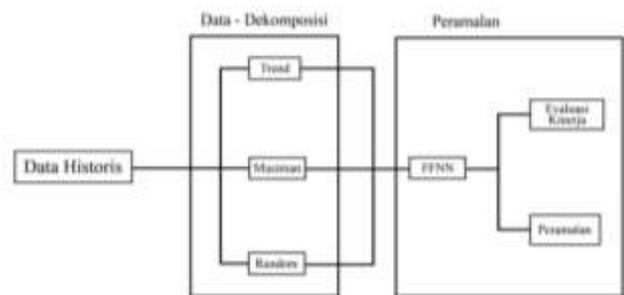
Pergerakan pada IHSG ditandai dengan adanya volatilitas. pergerakan turun menandakan bahwa kondisi pasar saat itu sedang lesu, jika terjadi kenaikan menandakan bahwa pasar saham sedang bergairah sedangkan untuk kondisi tidak berubah menandakan bahwa pasar saham stabil.

Volatilitas merupakan ukuran dari tingkat pergerakan harga sekuritas dari waktu ke waktu. Pelaku keuangan menghitung nilai volatilitas sekuritas untuk menentukan variansi harga data terdahulu untuk dapat memprediksi pergerakan ke depan. Volatilitas dapat ditentukan dengan melihat pada standar deviasi, nilai ini digunakan untuk mengukur jumlah penyebaran yang terjadi dalam harga sekuritas tersebut.

Peramalan terhadap volatilitas sangat diperlukan dalam berinvestasi dengan tujuan untuk melakukan pengelolaan keuntungan serta resiko kerugian (Poon & Granger, 2005). Banyak peneliti telah melakukan penelitian terkait nilai volatilitas antara lain (Ge et al., 2022) yang melakukan analisis peramalan volatilitas keuangan berbasis NN dari 35 penelitian yang berbeda; (Q. Chen & Robert, 2022) meramalkan volatilitas yang jangka pendek dengan menggunakan pendekatan multivariat (İltüzer, 2022). Penelitian-penelitian tersebut memberikan bukti bahwa volatilitas pada data keuangan memiliki nilai penting dalam melakukan investasi, manajemen resiko dan pembuatan kebijakan moneter

(Poon & Granger, 2003). Ketidakpastian dari volatilitas menjadi tanggung jawab bagi pelaku keuangan terutama investor dan manajer portofolio, karena kesalahan keputusan dalam berinvestasi dapat menyebabkan kerugian bagi pelaku keuangan. Ramalan volatilitas yang baik menjadi titik awal yang baik untuk menentukan resiko investasi.

Pada tahap analisis data, penelitian ini menggunakan model hybrid antara dekomposisi sebagai model statistik dan Feed Forward Neural (FFNN) sebagai model kecerdasan buatan. Selanjutnya data akan dievaluasi dan diramalkan untuk beberapa periode yang akan datang. Tahapan dari metode penelitian data terlihat pada gambar berikut.



Gambar 1. Struktur model yang dikembangkan

Model dekomposisi telah banyak digunakan dan dimanfaatkan untuk mengubah data menjadi beberapa bagian (Y. Chen et al., 2022). Bagian tersebut terdiri dari tren, musiman dan random.

- 1) Tren menunjukkan pergeseran secara bertahap dari data time series ke nilai yang lebih tinggi atau rendah dari waktu ke waktu. Tren menunjukkan ada atau tidaknya stationer dan komponen ini bersifat deterministik.
- 2) Musiman menunjukkan komponen berulang yang sama disajikan selama periode waktu yang berurutan. Komponen musiman ditunjukkan dengan adanya kestabilan dari waktu ke waktu dalam besaran maupun arah.
- 3) Random merupakan bagian yang tidak dapat dijelaskan dari time series yang terkadang naik melebihi tren dan musiman yang dapat menjadi tantangan untuk dilakukan peramalan dan bersifat stokastik (Mbuli et al., 2020).

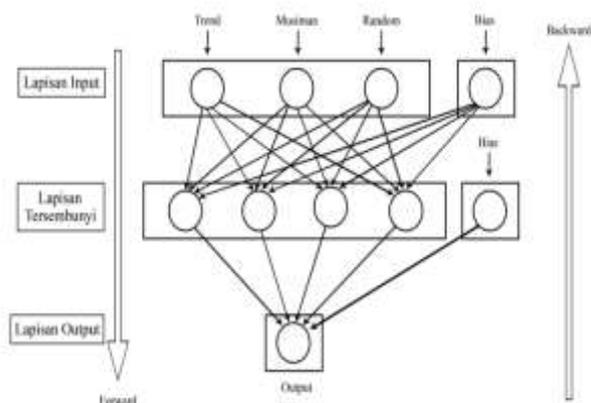
Analisis time series dengan menggunakan model statistik telah banyak digunakan untuk meramalkan data time series untuk waktu yang akan datang, namun ketika data yang digunakan merupakan data nonstasioner dan nonlinear maka kinerja model ini akan menurun (Rubi et al., 2022). Karena kemampuannya dalam mengatasi permasalahan nonlinear dan stasioneritas data menyebabkan NN banyak digunakan pada beberapa waktu terakhir ini.

Fungsi utama dari NN adalah memodelkan proses penalaran dari manusia sebagai algoritma komputer yang efisien atau NN merupakan kumpulan persamaan numerik. Satu atau lebih variabel input digunakan

kemudian di proses dengan persamaan yang akan menghasilkan satu atau lebih variabel output. Umumnya jaringan memiliki tiga lapisan yaitu lapisan input, tersembunyi dan output dan lapisan ini akan berisi satu atau lebih node (Chhajer et al., 2022).

Penelitian ini akan menggunakan jenis NN Feed Forward Neural Network (FFNN). FFNN termasuk pada pembelajaran yang terawasi dan merupakan model algoritma nonlinier standar yang baik serta memiliki fungsi perkiraan yang universal (Godahewa et al., 2021). FFNN dalam prosesnya memiliki banyak neuron yang saling terhubung dalam lapisannya, sehingga FFNN dapat menangkap fenomena yang kompleks. FFNN dilatih menggunakan data time series untuk menangkap karakteristik data. Parameter-parameter yang digunakan termasuk bobot dan bias disesuaikan secara iteratif dengan meminimalkan error global atau total square error.

Proses kerja dari FFNN dimulai dari neuron input menerima komponen data dari dataset dan meyebarkannya ke seluruh neuron pada lapisan tersembunyi. Masing-masing neuron hidden akan menghitung net input kemudian menghasilkan output. Seperti terlihat pada gambar 3.3 berikut.



Gambar 2. FFNN dengan Input Hasil Dekomposisi

Masalah dari algoritma FFNN adalah penentuan parameter-parameter yang akan digunakan pada algoritma tersebut. Banyak penelitian yang melakukan dengan menggunakan uji coba, namun beberapa penelitian telah memberikan beberapa model untuk menentukannya. Pengulangan beberapa kali dari algoritma BPNN akan meningkatkan akurasi namun akibatnya meningkatkan komputasi.

Model hybrid merupakan model yang menggabungkan dua atau lebih metode atau algoritma peramalan dan banyak penelitian telah menerapkan model ini. Model hybrid dilakukan dengan menggabungkan model statistik dan kecerdasan buatan. Seperti penelitian yang telah dilakukan (Yun et al., 2022) yang menggabungkan CEEMDAN dan LSTM dalam meramalkan sinyal harga karbon dan hasil penelitian menunjukkan bahwa model ini mampu memberikan akurasi yang signifikan dalam hkan harga tersebut; (Lee & Cho, 2022)menggabungkan antara model SARIMAX

dan LSTM untuk meramalkan volatilitas peningkatan permintaan listrik di Korea, hasil penelitian menunjukkan model ini mampu memberikan hasil peramalan yang signifikan.

Pengukuran kinerja dari model yang digunakan pada penelitian ini akan menggunakan Mean Absolute Error (MAE) dan Mean Square Error (MSE) yang merupakan ukuran yang digunakan pada peramalan data time series (Heng et al., 2022; Kumar et al., 2022).

$$MAE = \frac{1}{N} \sum_{i=1}^N (Y'_i - Y_i),$$

$$MSE = \sum_{i=1}^N \frac{(Y'_i - Y_i)^2}{N} \dots (2)$$

dimana adalah ouput prediksi, adalah ouput aktual, dan adalah jumlah sampel yang digunakan.

Data yang digunakan pada penelitian ini adalah data time series dari harga penutupan Indeks Harga Saham Gabungan (IHSG) yang di mulai dari tanggal 17 Mei s.d. 24 November 2022. Pengambilan data pada periode tersebut bertujuan untuk mengetahui volatilitas yang terjadi pada IHSG setelah keluarnya aturan di Indonesia untuk melepaskan masker di outdoor saat beraktivitas. Adapun data tersebut tersaji pada gambar 4.1. berikut.

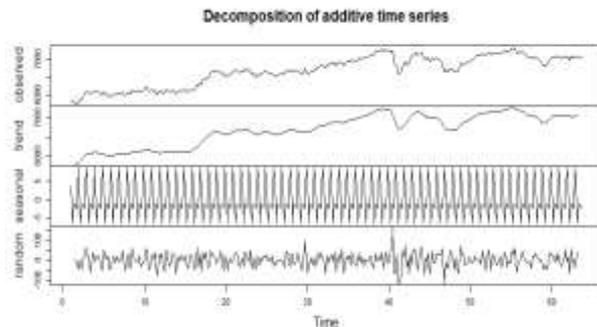


Gambar 3. Plot pergerakan harga IHSG

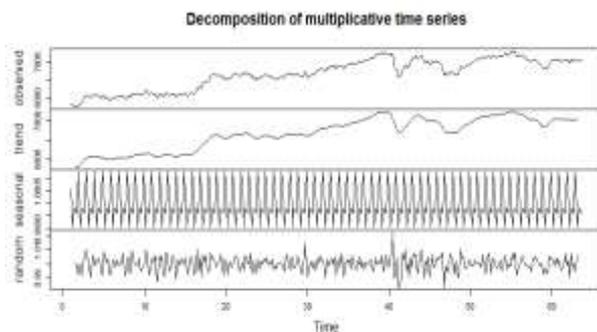
Gambar 3 meperlihatkan adanya volatilitas data yang terjadi pada harga IHSG, lonjakan yang terjadi kurang lebih 25 lonjakan yang sangat volatil terjadi untuk penurunan dan kenaikan harga IHSG. Gambar tersebut juga menunjukkan adanya kenaikan harga IHSG dengan beberapa periode peningkatan. Pola kenaikan terjadi di akhir 2022, april 2022, juni 2022, September 2022 sedangkan penurunan harga terjadi pada Mei 2021, Oktober 2021, Juni 2022, Agustus 2022 dan Otober 2022. Lonjakan ini membuat para pelaku keuangan harus mampu mencari strategi yang baik untuk dapat memanajemen resiko keuangan dari aset yang dimiliki.

Penelitian ini dilakukan dengan menggunakan dua model yang pertama adalah model statistik dengan dekomposisi dan model kedua merupakan model kecerdasan buatan dengan NN. Kedua model akan digabungkan dengan menggunakan hybrid. Untuk model dekomposisi akan dilakukan dengan dua

pendekatan yaitu additive dan multiplicative. Masing-masing pendekatan akan membagi data time series dari harga penutupan IHSG menjadi komponen musiman, trend dan random. Adapun plot hasil dekomposisi untuk kedua pendekatan dapat dilihat pada gambar berikut.



Gambar 4. Dekomposisi menggunakan pendekatan additive



Gambar 5. Dekomposisi menggunakan pendekatan multiplicative

Hasil dekomposisi kemudian dilanjutkan dengan menjadikan ketiga komponen sebagai inputan bagi jaringan NN. Pada NN akan dibentuk arsitektur jaringan dengan menggunakan lapisan tersembunyi yang berbeda. Lapisan tersembunyi ditentukan dengan menggunakan beberapa penelitian terdahulu antara lain adalah (Meng et al., 2016) dengan menggunakan persamaan $\frac{3^{N_i}}{(N_i+6)}$; (Wang & Hu, 2015) menggunakan rumus $\frac{\sqrt{N_i+N_0}}{2}$ untuk menentukan jumlah node pada lapisan tersembunyi; (Sheela & Deepa, 2014) $\frac{4N_i}{N_i-2}$ menggunakan persamaan tersebut untuk menentukan node lapisan tersembunyi; serta (Saluza & Anggraini, 2022) menggunakan formula $\frac{6N_i}{(N_i+1)}$ untuk menentukan node. Berdasarkan persamaan tersebut secara berurut diperoleh node lapisan tersembunyi berikut: 3, 1, 12, 4 atau 5.

Berdasarkan kelima node lapisan tersembunyi yang diperoleh selanjutnya akan dibuat arsitektur jaringan dengan membandingkan epoch yang digunakan saat melatih jaringan. Epoch yang digunakan yaitu 50, 100, 150 dan 200. Berdasarkan perbedaan arsitektur dan epoch yang digunakan akan dibandingkan kinerja jaringan dalam memprediksi harga IHSG. Selanjutnya

dalam melatih jaringan akan digunakan cross validasi sebanyak 70% untuk pelatihan dan 30% untuk pengujian. Hasil dari masing-masing arsitektur yang berbeda akan dibandingkan untuk melihat kinerja model hybrid yang digunakan. berikut hasil perbandingan kinerja yang dapat dirangkum.

Tabel 1. Kinerja model hybrid menggunakan dekomposisi additive

Cross Validasi		Training		Testing	
Epoch	Node	MAE	MSE	MAE	MSE
50	1	0.2737	0.1090	0.3203	0.1780
	3	0.2643	0.1049	0.3118	0.1681
	4	0.2676	0.1041	0.2697	0.1283
	5	0.2058	0.0758	0.2409	0.1072
	12	0.1934	0.0668	0.1389	0.0420
100	1	0.2737	0.1090	0.3470	0.1998
	3	0.2695	0.1066	0.3480	0.2002
	4	0.2629	0.1023	0.2631	0.1259
	5	0.2398	0.0880	0.2183	0.0888
	12	0.2016	0.0650	0.1232	0.0400
150	1	0.2737	0.1090	0.3424	0.1929
	3	0.2044	0.0774	0.2848	0.1397
	4	0.2056	0.0770	0.2647	0.1199
	5	0.2038	0.0762	0.2750	0.1395
	12	0.1897	0.0658	0.1092	0.0356
200	1	0.2737	0.1090	0.3203	0.1780
	3	0.2673	0.1042	0.2948	0.1480
	4	0.2620	0.0998	0.2422	0.1122
	5	0.2064	0.0754	0.2361	0.1151
	12	0.2099	0.0740	0.1002	0.0314

Berdasarkan tabel 1 dapat disimpulkan bahwa semakin banyak node pada lapisan tersembunyi yang digunakan maka kinerja jaringan semakin baik untuk data training dan testing, sedangkan untuk epoch yang digunakan dari tabel terlihat bahwa epoch dengan jumlah 100 memberikan hasil kinerja yang optimum. Artinya jumlah epoch yang terlalu banyak belum tentu memberikan hasil kinerja yang baik.

Tabel 2. Kinerja model hybrid menggunakan dekomposisi multiplicative

Cross Validasi		Training		Testing	
Epoch	Node	MAE	MSE	MAE	MSE
50	1	0.2737	0.1090	0.3203	0.1780
	3	0.2062	0.0755	0.3063	0.1606
	4	0.2640	0.1026	0.2789	0.1345
	5	0.2127	0.0780	0.2474	0.1064
	12	0.1807	0.0635	0.1523	0.0428
100	1	0.2737	0.1090	0.3350	0.1905
	3	0.2043	0.0774	0.2962	0.1473
	4	0.2047	0.0746	0.2582	0.1109
	5	0.1874	0.0656	0.2412	0.1044
	12	0.1849	0.0631	0.0268	0.1040
150	1	0.2737	0.1090	0.3478	0.2000
	3	0.2596	0.1005	0.2724	0.1319
	4	0.2665	0.1048	0.2732	0.1240
	5	0.2054	0.0769	0.2244	0.0937

	12	0.1739	0.0601	0.1495	0.0473
	1	0.2737	0.1090	0.1890	0.3307
	3	0.2649	0.1047	0.2853	0.1395
200	4	0.2066	0.0792	0.2533	0.1125
	5	0.1646	0.0540	0.2699	0.1176
	12	0.1873	0.0614	0.1246	0.0359

Tabel 2 memberikan hasil kinerja model *hybrid*, sama halnya pada model *hybrid* menggunakan dekomposisi *additive* hasil kinerja jaringan akan semakin baik jika jumlah node lapisan tersembunyi semakin banyak. Sedangkan untuk epoch yang baik pada dekomposisi *multiplicative* adalah sebanyak 150 epoch

Table 3. Kinerja Model *hybrid* dan NN tunggal

Model	Epoch	Node	Training		Testing	
			MSE	MAE	MSE	MAE
<i>hybrid</i> NN & pendekatan dekomposisi <i>additive</i>	100	12	0.2016	0.0650	0.1232	0.0400
<i>Hybrid</i> NN & pendekatan dekomposisi <i>multiplicative</i>	150	12	0.1739	0.0601	0.1495	0.0473
NN Tunggal	200	12	0.531	0.238	0.380	0.109

Tabel 3 menunjukkan bahwa kinerja model *hybrid* memberikan kinerja yang baik untuk MAE dan MSE dibandingkan dengan NN tunggal tanpa penggabungan. Model *hybrid* yang memberikan kinerja lebih baik adalah NN dan pendekatan dekomposisi *multiplicative*.



Gambar 6. Plot Perbandingan Model *Hybrid* dan Data Aktual

Gambar 6 merupakan gambar hasil prediksi data harga penutupan IHSG yang dibandingkan dengan model *hybrid* dan NN tunggal. Terlihat bahwa model *hybrid* memberikan hasil yang lebih baik dari pada NN tunggal dan untuk kedua bentuk dekomposisi model *hybrid* tetap memberikan hasil prediksi yang mendekati data aktual.

3. Kesimpulan

Pergerakan IHSG sangat menunjukkan volatilitas terutama semenjak tahun 2022, volatilitas data tersebut sangat mengancam bagi para pelaku keuangan, terutama pelaku keuangan yang memiliki investasi. Kenaikan dan penurunan yang sangat besar terjadi membuat para

pelaku keuangan harus mampu membuat strategi keuangan mengenai aset yang dimiliki. Salah satu cara yang dapat dilakukan adalah dengan memprediksi pergerakan data IHSG sebagai acuan dalam berinvestasi. Dalam penerapannya prediksi telah dilakukan oleh banyak peneliti dengan berbagai model. Penelitian ini melakukan prediksi menggunakan model *hybrid* dengan menggabungkan model dekomposisi dan model NN. Model dekomposisi yang digunakan dibedakan dengan menggunakan pendekatan *additive* dan *multiplicative*, kemudian hasil dari dekomposisi akan dilanjutkan dengan menggabungkannya dengan NN. Hasil penelitian menggunakan model *hybrid* menunjukkan kinerja yang sangat baik dalam memprediksi data aktual dari harga IHSG yang volatil, terlihat bahwa model *hybrid* mampu mengikuti pergerakan harga IHSG dibandingkan dengan NN tunggal yang digunakan untuk memprediksi.

Daftar Pustaka

Ahmad, E., Stern, N., & Xie, C. (2020). From rescue to recovery: towards a post-pandemic sustainable transition for China. ... //Cdrf. Org. Cn/Jjh/Pdf/Towards a Post-Pandemic ..., June, 1–28.

Ahmad, T. (2022). Pertumbuhan Ekonomi Indonesia di Masa Pandemi Cenderung Negatif. *Muttaqien*, 3(1), 67–77.

Anhika Viadinugroho, R. A., & Rosadi, D. (2021). Long Short-Term Memory Neural Network Model for Time Series Forecasting: Case Study of Forecasting IHSG during Covid-19 Outbreak. *Journal of Physics: Conference Series*, 1863(1). <https://doi.org/10.1088/1742-6596/1863/1/012016>

Chen, Q., & Robert, C.-Y. (2022). Multivariate Realized Volatility Forecasting with Graph Neural Network. In *3rd ACM International Conference on AI in Finance (ICAIF '22)*, November 2â•fi4, 2022, New York, NY, USA (Vol. 1, Issue 1). Association for Computing Machinery. <https://doi.org/10.1145/3533271.3561663>

Chen, Y., Zhao, P., Zhang, Z., Bai, J., & Guo, Y. (2022). A Stock Price Forecasting Model Integrating Complementary Ensemble Empirical Mode Decomposition and Independent Component Analysis. *International Journal of Computational Intelligence Systems*, 15(1). <https://doi.org/10.1007/s44196-022-00140-2>

Chhajer, P., Shah, M., & Kshirsagar, A. (2022). The applications of artificial neural networks, support vector machines, and long–short term memory for stock market prediction. *Decision Analytics Journal*, 2(June 2021), 100015. <https://doi.org/10.1016/j.dajour.2021.100015>

Chowdhury, E. K., Dhar, B. K., & Stasi, A. (2022). Volatility of the US stock market and business strategy during COVID-19. *Business Strategy and Development*, April. <https://doi.org/10.1002/bsd2.203>

Christianti, A. (2018). *Volatility Shock Persistence in Investment Decision Making: a Comparison Between*

- the Consumer Goods and Property-Real Estate Sectors of the Indonesian Capital Market*. *Journal of Indonesian Economy and Business*. <https://doi.org/10.22146/jieb.23225>
- Gao, X., Ren, Y., & Umar, M. (2022). To what extent does COVID-19 drive stock market volatility? A comparison between the U.S. and China. *Economic Research-Ekonomika Istrazivanja*, 35(1), 1686–1706. <https://doi.org/10.1080/1331677X.2021.1906730>
- Ge, W., Lalbakhsh, P., Isai, L., Lenskiy, A., & Suominen, H. (2022). *Neural Network – Based Financial Volatility Forecasting*: 55(1), 1–30.
- Godahewa, R., Bandara, K., Webb, G. I., Smyl, S., & Bergmeir, C. (2021). Ensembles of localised models for time series forecasting. *Knowledge-Based Systems*, 233. <https://doi.org/10.1016/j.knosys.2021.107518>
- google berita. (n.d.). *Virus Corona (Covid-19)*. Google Berita.
- Gunawan, D., & Astika, W. (2022). The Autoregressive Integrated Moving Average (ARIMA) Model for Predicting Jakarta Composite Index. *Jurnal Informatika Ekonomi Bisnis*, 4(January 2020), 2–7. <https://doi.org/10.37034/infv4i1.114>
- Hanoatubun, S. (2020). Dampak Pandemi COVID-19 terhadap Perekonomian Indonesia [Impact of the COVID-19 Pandemic on the Indonesian Economy]. *Journal of Education, Psychology and Counseling*, 2(1), 212. <https://doi.org/10.31289/agri.v4i2.8247>
- Heng, S. Y., Ridwan, W. M., Kumar, P., Ahmed, A. N., Fai, C. M., Birima, A. H., & El-Shafie, A. (2022). Artificial neural network model with different backpropagation algorithms and meteorological data for solar radiation prediction. *Scientific Reports*, 12(1), 1–18. <https://doi.org/10.1038/s41598-022-13532-3>
- Heryati, A., & Herdiansyah, M. I. (2020). The Application of Data Mining by using K-Means Clustering Method in Determining New Students' Admission Promotion Strategy. *International Journal of Engineering and Advanced Technology*, 9(3), 824–833. <https://doi.org/10.35940/ijeat.c5414.029320>
- Heryati, A., Martadinata, A. T., & Syahputra, R. (2021). Penerapan Metode Simple Additive Weighting (Saw) Pada Sistem Pendukung Keputusan Penentuan Penerimaan Dosen Baru. *JUSIM (Jurnal Sistem Informasi Musirawas)*, 6(1), 80–90. <https://doi.org/10.32767/jusim.v6i1.1212>
- Heryati, A., Menzata Z, R. A., & Afriyani, F. (2019). The impact of Occupational Health and Safety (OHS) training and compensation on employees' performance. *Test Engineering and Management*, 81(11–12), 3486–3492.
- İltüzer, Z. (2022). Option pricing with neural networks vs. Black-Scholes under different volatility forecasting approaches for BIST 30 index options. *Borsa Istanbul Review*, 22(4), 725–742. <https://doi.org/10.1016/j.bir.2021.12.001>
- Insmanthono, H. W. (2003). *Kamus Istilah Ekonomi Populer* (Cyprianus Louis Noviatno (ed.)). Kompas.
- Kumar, G., Singh, U. P., & Jain, S. (2022). An adaptive particle swarm optimization-based hybrid long short-term memory model for stock price time series forecasting. *Soft Computing*, 26(22), 12115–12135. <https://doi.org/10.1007/s00500-022-07451-8>
- Lee, J., & Cho, Y. (2022). National-scale electricity peak load forecasting: Traditional, machine learning, or hybrid model? *Energy*, 239, 1–42. <https://doi.org/10.1016/j.energy.2021.122366>
- Li, W., Chien, F., Kamran, H. W., Aldeehani, T. M., Sadiq, M., Nguyen, V. C., & Taghizadeh-Hesary, F. (2022). The nexus between COVID-19 fear and stock market volatility. *Economic Research-Ekonomika Istrazivanja*, 35(1), 1765–1785. <https://doi.org/10.1080/1331677X.2021.1914125>
- Li, Z., Farmanesh, P., Kirikkaleli, D., & Itani, R. (2022). A comparative analysis of COVID-19 and global financial crises: evidence from US economy. *Economic Research-Ekonomika Istrazivanja*, 35(1), 2427–2441. <https://doi.org/10.1080/1331677X.2021.1952640>
- Mbuli, N., Mathonsi, M., Seitshiro, M., & Pretorius, J. H. C. (2020). Decomposition forecasting methods: A review of applications in power systems. *Energy Reports*, 6(2020), 298–306. <https://doi.org/10.1016/j.egy.2020.11.238>
- Meng, A., Ge, J., Yin, H., & Chen, S. (2016). Wind speed forecasting based on wavelet packet decomposition and artificial neural networks trained by crisscross optimization algorithm. *Energy Conversion and Management*, 114, 75–88. <https://doi.org/10.1016/j.enconman.2016.02.013>
- Moslehpour, M., Al-Fadly, A., Ehsanullah, S., Chong, K. W., Xuyen, N. T. M., & Tan, L. P. (2022). Assessing Financial Risk Spillover and Panic Impact of Covid-19 on European and Vietnam Stock market. *Environmental Science and Pollution Research*, 29(19), 28226–28240. <https://doi.org/10.1007/s11356-021-18170-2>
- Poon, S. H., & Granger, C. (2005). Practical issues in forecasting volatility. *Financial Analysts Journal*, 61(1), 45–56. <https://doi.org/10.2469/faj.v61.n1.2683>
- Poon, S. H., & Granger, C. W. J. (2003). Forecasting volatility in financial markets: A review. *Journal of Economic Literature*, 41(2), 478–539. <https://doi.org/10.1257/jel.41.2.478>
- Robiyanto, R. (2018). the Effect of Gold Price Changes, Usd/Idr Exchange Rate Changes and Bank Indonesia (Bi) Rate on Jakarta Composite Index (Jci)'S Return and Jakarta Islamic Index (Jii)'S Return. *Jurnal Manajemen Dan Kewirausahaan*, 20(1), 45. <https://doi.org/10.9744/jmk.20.1.45-52>
- Rubi, M. A., Chowdhury, S., Rahman, A. A. A., Meero, A., Zayed, N. M., & Anwarul Islam, K. M. (2022). Fitting Multi-Layer Feed Forward Neural Network and Autoregressive Integrated Moving Average for Dhaka Stock Exchange Price Predicting. *Emerging Science Journal*, 6(5), 1046–1061. <https://doi.org/10.28991/ESJ-2022-06-05-09>

- Saluza, I., & Anggraini, L. D. (2022). BPNN ' s Empirical Analysis of Daily Rupiah Exchange Rate Volatility Utilizing. *JURNAL AKSI Akuntansi Dan Sistem Informasi*, 7(1), 41–51.
- Sheela, K. G., & Deepa, S. N. (2014). Selection of number of hidden neurons in neural networks in renewable energy systems. *Journal of Scientific and Industrial Research*, 73(10), 686–688.
- Tjandrasa, B. B., & Sutjiati, R. (2016). Effect of World Gold Price, Crude Oil Price and Interest Rate to Jakarta Composite Index. *International Journal of Education and Research*, 4(7), 215–222.
- Wang, J., & Hu, J. (2015). A robust combination approach for short-term wind speed forecasting and analysis - Combination of the ARIMA (Autoregressive Integrated Moving Average), ELM (Extreme Learning Machine), SVM (Support Vector Machine) and LSSVM (Least Square SVM) forecasts. *Energy*, 93, 41–56. <https://doi.org/10.1016/j.energy.2015.08.045>
- Yun, P., Huang, X., Wu, Y., & Yang, X. (2022). Forecasting carbon dioxide emission price using a novel mode decomposition machine learning hybrid model of CEEMDAN-LSTM. *Energy Science and Engineering*, April. <https://doi.org/10.1002/ese3.1304>