

Optimisasi Backpropagation Neural Network dalam Memprediksi IHSG

Hartati¹⁾, Alpin Herman Saputra²⁾ Imelda Saluza³⁾

¹⁾Program Studi Matematika Universitas Terbuka

²⁾Program Studi PGSD Universitas Terbuka

³⁾Program Studi Manajemen Informatika Universitas Indo Global Mandiri

Jalan Cabe Raya Pondok Cabe, Kota Tangerang Selatan, 30137

Email : hartati@ecampus.ut.ac.id¹⁾, Alpin@ecampus.ut.ac.id²⁾, imeldasaluza@uigm.ac.id³⁾

ABSTRACT

Covid-19 has become a global epidemic and has spread to many countries in the world, including Indonesia. The COVID-19 pandemic is one source of uncertainty that causes financial data to fluctuate and cause data to be volatile. This outbreak had an impact on financial data, not only on the Rupiah exchange rate but also on the Jakarta Composite Index (JCI). The uncertainty of the JCI makes it difficult for investors, data managers, and business people to predict data for the future. JCI is one indicator of the capital market (stock exchange). The uncertainty of the JCI data causes the need for predictions, so that investors, data managers, and business people can make the right decisions so that they can reduce risk and optimize profits when investing. One of the factors causing the JCI's decline was sentiment caused by investor panic over the rapid spread of COVID-19 in various cities in Indonesia. This research uses Backpropagation Neural Network (BPNN) in making predictions and continues with optimization of BPNN using ensemble techniques. Historical data from the JCI used were obtained from yahoo.finance. The ensemble technique used consists of two approaches, namely combining different architectures and initial weights with the same data and combining different architectures and weights. The results of network performance using ensemble technique optimization show good performance and can outperform the individual network performance of BPNN.

Keywords: prediction, JCI, Optimization, BPNN, volatile

ABSTRAK

Covid-19 telah menjadi wabah global dan telah menyebar di banyak negara di dunia termasuk Indonesia. Pandemi covid-19 merupakan salah satu sumber ketidakpastian yang menyebabkan data keuangan mengalami fluktuatif dan menyebabkan data volatil. Wabah ini memberi dampak terhadap data keuangan, tidak hanya pada nilai tukar Rupiah tetapi juga Indeks Harga Saham Gabungan (IHSG). Ketidakpastian IHSG menyebabkan para investor, pengelola data, pelaku bisnis sulit untuk memperkirakan data untuk waktu yang akan datang. IHSG merupakan salah satu indikator pasar modal (bursa efek). Ketidakpastian data IHSG menyebabkan perlunya dilakukan prediksi, agar para investor, pengelola data, pelaku bisnis dapat mengambil keputusan yang tepat sehingga dapat menurunkan resiko dan mengoptimalkan keuntungan saat berinvestasi. Salah satu faktor penyebab penurunan IHSG adalah sentimen yang disebabkan dari kepanikkan investor atas penyebaran covid-19 yang begitu cepat di berbagai kota Indonesia. Penelitian ini menggunakan Backpropagation Neural Network (BPNN) dalam melakukan prediksi dan dilanjutkan dengan optimisasi BPNN menggunakan teknik ansambel. Data historical dari IHSG digunakan yang diperoleh dari yahoo.finance. Teknik ansambel yang digunakan terdiri dari dua pendekatan yaitu penggabungan arsitektur dan bobot awal berbeda dengan data sama dan penggabungan arsitektur dan bobot berbeda. Hasil kinerja jaringan menggunakan optimisasi teknik ansambel menunjukkan kinerja yang baik dan dapat mengungguli kinerja jaringan individual dari BPNN.

Kata kunci: prediksi, IHSG, optimisasi, BPNN, volatil



Article History

Received : 06/01/2022
Revised : 17/01/2022
Accepted : 01/03/2022
Online : 30/03/2022



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

1. Pendahuluan

Perkembangan teknologi, produk keuangan terbaru, kemampuan keuangan dan manajemen resiko banyak memberikan dampak terhadap kemajuan pasar keuangan (Yin *et al.*, 2017). Hal ini berdampak kepada banyaknya data historis yang disimpan secara elektronik bahkan akan meningkat jumlahnya untuk waktu yang akan datang. Data tersebut disimpan, namun kenyataannya meskipun data tersebut telah tersimpan banyak pengelola dana kurang memanfaatkan data tersebut (Kannan *et al.*, 2010). Hal ini dikarenakan sulitnya mendapatkan informasi tersirat dari sekelompok data tersebut dan membuat pengelola dana mengalami kesulitan dalam merencanakan pendanaan untuk waktu yang akan datang. Dan menyebabkan banyak peneliti melakukan penelitian untuk memprediksi fenomena data keuangan tersebut.

Salah satu peran dari prediksi adalah kemampuannya dalam menangani ketidakpastian data keuangan terutama data yang memiliki tren dan variasi data sehingga menyebabkan volatilitas yang berfluktuatif. Saat ini, Indonesia dan dunia memiliki data keuangan dengan volatilitas yang sangat berfluktuatif dikarenakan pandemi covid-19.

Covid-19 telah menjadi wabah global dan telah menyebar di 215 negara di dunia. Peningkatan jumlah penderita dengan *fatality rate* yang masih tinggi membawa Indonesia masuk ke dalam resesi yang lebih dalam, hal ini ditunjukkan dengan anjloknya perekonomian kuartal II menjadi minus 5,32% dari 2,97% pada kuartal I. Hal ini membuktikan bahwa perekonomian Indonesia tertekan sangat dalam akibat pandemi ini (Suryaputri and Kurniawati, 2020).

Covid-19 tidak hanya berdampak pada nilai tukar Rupiah, wabah ini juga mempengaruhi laju penurunan Indeks Harga Saham Gabungan (IHSG). IHSG merupakan salah satu indikator pasar modal (bursa efek). IHSG digunakan untuk mengukur kinerja semua saham yang tercatat di Papan Utama dan Papan Pengembangan Bursa Efek Indonesia (Sciences, 2016). Sentimen penurunan IHSG disebabkan kepanikkan investor atas penyebaran covid-19 yang begitu cepat di berbagai kota Indonesia. Pelaku pasar merespon berbagai berita negatif dari covid-19, dan berdampak terhadap laju IHSG. Sepanjang Maret 2020 regulator pasar modal telah memberlakukan enam kali *trading halt* (penghentian sementara perdagangan) karena laju IHSG mengalami pelemahan yang sangat tajam yaitu lebih dari 5% (Efek, Pada and Pandemi, 2021).

Banyak metode prediksi yang digunakan saat ini menerapkan model-model statistik, model yang sering digunakan antara lain *exponential smoothing*, *AutoRegressive Integrated Moving Average* (ARIMA) atau *Box-Jenkins* dimana model-model tersebut mampu menangkap kelinieran data sehingga model tersebut lebih cocok digunakan untuk data time series linier. Sedangkan untuk data time series nonlinier model yang sering digunakan adalah *Artificial Neural Networks* (ANN), *fuzzy*, dan sebagainya. Pemilihan model-model

yang digunakan pada perhitungan prediksi bergantung pada berbagai aspek yang mempengaruhi, seperti aspek waktu, pola data, tipe model sistem yang diamati, tingkat keakuratan peramalan yang diinginkan dan sebagainya.

Banyak penelitian yang telah menggunakan NN sebagai metode untuk memprediksi data, karena kemampuannya dalam mengatasi data volatil. Salah satu algoritma NN yang paling banyak digunakan dalam memprediksi adalah *Backpropagation Neural Network* (BPNN). Pada dasarnya apakah model tersebut “baik” bergantung kepada bagaimana model tersebut dapat memenuhi persyaratan yang telah ditentukan oleh pengelola dana atau investor. Masing-masing pengelola dana atau investor tentunya memiliki harapan yang berbeda-beda pada masing-masing pembelajaran yang dilakukan dalam peramalan. Salah satu strategi yang telah banyak digunakan adalah dengan melakukan evaluasi dari masing-masing model yang telah dilatih dalam pembelajaran data time series yang digunakan untuk selanjutnya meramalkan kinerja model tersebut dan kemudian membiarkan pengelola dana atau investor untuk memutuskan apakah model tersebut dapat diterima atau memilih model terbaik dari serangkaian kandidat yang ada.

Keunggulan dari BPNN antara lain adalah struktur nonlinier yang dimilikinya. Struktur nonlinier mampu memperhitungkan hubungan-hubungan yang lebih kompleks dari data yang di analisis sehingga mampu memperamalan data menjadi lebih akurat (Siwek, Osowski and Szupiluk, 2009), sedangkan dalam penerapannya BPNN telah terbukti secara empiris mampu meramalkan baik linier maupun nonlinier data deret waktu dari bentuk-bentuk yang berbeda (Zhang, 2003). Serta pada data keuangan BPNN telah berhasil diterapkan, baik dalam melakukan peramalan serta tujuan perlindungan nilai (Dyah Puspitaningrum, 2006). Namun Kemampuan aproksimasi dari BPNN yang kuat dan pendekatan pemodelan self-adaptive data driven memungkinkan BPNN memiliki fleksibilitas yang besar dalam pemodelan data time series. Hal ini dapat memperumit spesifikasi model secara substansial dalam memberikan parameter-parameter yang terdapat pada BPNN (Kourentzes, Barrow and Crone, 2014).

Pendekatan yang sangat sering dilakukan saat melakukan prediksi menggunakan BPNN adalah dengan memilih satu jaringan yang memberikan kinerja terbaik dengan melakukan *training* berulang-ulang. Proses *training* yang dilakukan berulang-ulang dapat menyebabkan terjadinya *overfitting*. Terjadinya *overfitting* mendorong banyak peneliti untuk melakukan optimasi dengan tujuan memperbaiki kinerja BPNN sehingga memberikan hasil prediksi yang akurat.

Salah satu optimisasi BPNN yang banyak digunakan peneliti yaitu teknik ensemble. Beberapa penelitian menunjukkan hasil bahwa teknik ansambel memberikan peningkatan kinerja yang signifikan dibanding hasil prediksi jaringan individual BPNN (Siwek, Osowski and Szupiluk, 2009). Selain itu keunggulan dari teknik ansambel yang lain adalah mampu meningkatkan akurasi (Naftaly, Intrator and Horn, 1997), mampu mengontrol

error yang dihasilkan karena proses penggabungan output jaringan prediktor yang dilakukan pada teknik ini (Jeong and Kim, 2005), dan mampu mengatasi permasalahan *overfitting* pada jaringan individual BPNN (Melin *et al.*, 2020).

Tujuan dari penelitian ini adalah melakukan teknik optimisasi BPNN yang mampu memberikan kinerja terbaik sehingga memberikan hasil prediksi yang akurat serta mampu mengatasi masalah *overfitting* jaringan individual.

2. Metode Penelitian

A. Backpropagation Neural Network (BPNN)

Model-model NN ditentukan oleh arsitektur jaringan serta algoritma pelatihan. Arsitektur akan menjelaskan kemana arah perjalanan sinyal atau data di dalam jaringan, sedangkan algoritma belajar menjelaskan bagaimana bobot koneksi harus diubah agar pasangan masukan-keluaran yang diinginkan dapat tercapai. Model NN terbagi menjadi layar tunggal dan jamak. Pada jaringan layar tunggal, sekumpulan input langsung dihubungkan dengan output. Contohnya model *adaline*, *perceptron*, dan sebagainya. Sedangkan layar jamak diantara lapisan input dan output terdapat lapisan *hidden* yang menghubungkan keduanya. Contohnya *madaline*, *backpropagation*.

Backpropagation merupakan model jaringan NN dengan layer jamak. Seperti halnya model jaringan syaraf tiruan lainnya, *backpropagation* melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan serta kemampuan jaringan untuk memberikan respon yang benar terhadap pola masukan yang serupa (tapi tidak sama) dengan pola yang dipakai selama pelatihan.

Menurut (Dyah Puspitaningrum, 2006) BPNN terdiri dari banyak lapisan (*multilayer neural networks*):

1. Lapisan input (1 buah). Lapisan input terdiri dari neuron-neuron atau node-node input, mulai dari node input 1 sampai dengan n.
2. Lapisan tersembunyi (minimal 1). Lapisan input terdiri neuron-neuron atau node-node tersembunyi, mulai dari node tersembunyi 1 sampai dengan p.
3. Lapisan output (1 buah). Lapisan output terdiri dari node-node output 1 sampai dengan m.

Secara umum, persamaan peramalan model jaringan syaraf dengan satu lapisan tersembunyi untuk perhitungan peramalan \hat{y}_t (output atau target) menggunakan input observasi masa lalu $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ biasa di tulis dalam bentuk [11]:

$$\hat{y}_t = \psi_h \left(w_{h0} + \sum_{j=1}^p w_{hj} \psi_j \left(v_{j0} + \sum_{i=1}^n v_{ji} x_i \right) \right) \tag{1}$$

B. Teknik Ensemble

Teknik ensemble pada penelitian ini menggunakan pendekatan *simple averaging*. Pendekatan ini dilakukan dengan merata-ratakan hasil prediksi dari masing-masing jaringan individual BPNN. Dengan mengasumsikan

bahwa semua prediktor adalah $w_i = \frac{1}{n}$ untuk $n = 1, 2, \dots, n$ diperoleh:

$$\hat{f}(x) = \frac{\sum_{i=1}^n f_i(x)}{n} \tag{2}$$

dimana
 $\hat{f}(x)$ = output prediktor ensemble
 $f_i(x)$ = Output jaringan individual BPNN ke-*i* pada input *x*

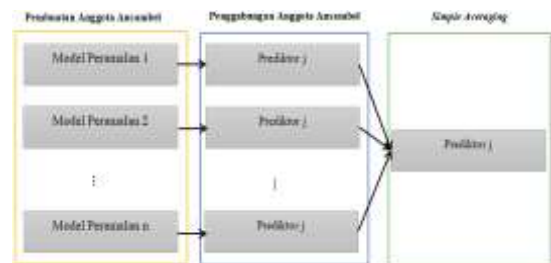
Dianggap output yang diinginkan dari *x* adalah $d(x) = \{d_1(x), d_2(x), \dots, d_n(x)\}$, kemudian $e_i(x)$ merupakan generalisasi error dari jaringan syaraf individual ke-*i* pada *x* input dan $\hat{e}(x)$ merupakan generalisasi error dari hasil ramalan ensemble pada *x*. Generalisasi error $\hat{e}(x)$ dari hasil ramalan ensemble dapat ditunjukkan pada persamaan berikut

$$\hat{e}(x) = \hat{f}(x) - d(x) = (f^{(1)}(x) - d^{(1)}(x), f^{(2)}(x) - d^{(2)}(x), \dots, f^{(m)}(x) - d^{(m)}(x)) \tag{3}$$

Beberapa percobaan yang menggunakan pendekatan *simple averaging* adalah pendekatan yang efektif digunakan, terlebih saat anggota-anggota ansambel memiliki minimum lokal yang berbeda atau dengan kata lain anggota ensemble beragam (Yang *et al.*, 2019).

C. Rancangan Ensemble

Penelitian ini bertujuan untuk memperbaiki hasil prediksi IHSG menggunakan optimisasi dengan teknik ansambel BPNN. Arsitektur teknik ansambel yang digunakan digambarkan sebagai berikut.



Gambar 1. Arsitektur Teknik Ansambel

Gambar 1 memberikan gambaran mengenai teknik ansambel. Arsitektur teknik ansambel terdiri dari tiga tahapan, yaitu pembuatan anggota ansambel yang dilakukan dengan prediksi menggunakan masing-masing model sebanyak *j* model prediksi untuk masing-masing BPNN. Selanjutnya hasil prediksi pada masing-masing model akan digabungkan menggunakan teknik ansambel *simple averaging*.

D. Evaluasi Statistik

Evaluasi statistik yang digunakan pada penelitian ini adalah Mean Square Error (MSE) dan Mean Absolute Error (MAE). Kedua pengukuran error ini digunakan untuk karena mampu mengenal dengan pasti signifikansi hubungan antara data aktual dan data hasil prediksi dengan seberapa besar error yang dihasilkan. Kedua pengukuran statistik tersebut didapat dari persamaan berikut.

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{4}$$

dengan,

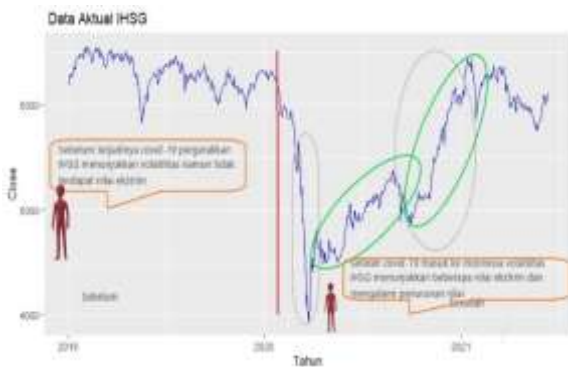
- n = bilangan ramalan
- y_t = nilai aktual pada waktu t
- \hat{y}_t = nilai ramalan pada waktu t

3. Hasil dan Pembahasan

A. Data Penelitian

Berdasarkan hasil-hasil penelitian terdahulu mengenai keberhasilan penerapan BPNN dalam bidang keuangan serta masalah dalam neural network yakni *overfitting*, maka dalam penelitian ini dilakukan studi kasus untuk mencari teknik yang dapat mengurangi masalah *overfitting* dalam neural network sehingga memberikan hasil prediksi yang baik. Dalam penelitian ini, studi kasus dilakukan terhadap Indeks Harga Saham Gabungan (IHSG). Data yang digunakan merupakan data harian dari kedua data tersebut. Data dibagi menjadi dua yaitu sebelum dan setelah covid-19 masuk ke Indonesia, untuk data sebelum covid-19 peneliti mengambil mulai dari tanggal 1 Maret 2017 sampai dengan 28 Februari 2020 sedangkan data untuk setelah covid-19 adalah mulai dari tanggal 1 Maret 2017 sampai dengan 30 juni 2021. Data harian didapat dari finance.yahoo.com.

Untuk memeriksa keefektifan dari teknik ensemble Neural Network, semua data yang ada di bagi menjadi tiga bagian yaitu kelompok data training, kelompok data validation serta kelompok data selanjutnya kelompok data testing.



Gambar 2. Plot IHSG sebelum Vs Setelah covid-19

Gambar 1 terdiri dari dua bagian data, sebelum dan setelah Indonesia mengalami pandemi covid-19. Gambar menunjukkan bahwa nilai IHSG mengalami dampak signifikan dari terjadinya pandemik covid-19 yang ditunjukkan dengan plot tidak linier dengan volatilitas tinggi disertai nilai-nilai ekstrim yang ditandai dengan lingkaran berwarna hijau. Gambar 1 memperlihatkan bahwa di waktu awal covid-19 masuk ke Indonesia harga IHSG mengalami penurunan disertai keekstriman nilai.

Namun terbalik dengan gambar 1 dimana IHSG mengalami penurunan yang ditunjukkan volatilitas tinggi disertai nilai ekstrim. Gambar 1 memberikan informasi agar semua pelaku ekonomi, bisnis, dan investor untuk lebih berhati-hati dalam melakukan transaksi di pasar modal. Dan tentunya menjadi tugas pemerintah dan semua masyarakat Indonesia untuk memperbaiki kondisi perekonomian dan keuangan selama pademi covid-19 mewabah di Indonesia.

Data time series pada penelitian ini terdiri dari data IHSG dimana data dibagi menjadi dua yaitu data sebelum dan setelah covid-19 masuk ke Indonesia. Data time series yang ada dilakukan cross validation dengan cara membagi masing-masing data time series menjadi tiga bagian. Untuk data training sebanyak 70% dari keseluruhan data yang digunakan untuk pembentukan model jaringan NN serta pembentukan model untuk teknik ensemble, untuk data validasi sebanyak 15% dari keseluruhan data digunakan untuk pemvalidan model yang telah dilakukan pada kelompok data training, dan yang terakhir untuk data testing sebanyak 15% dari keseluruhan data digunakan untuk mengevaluasi hasil ansambel jaringan syaraf. Hasil cross validasi dari penelitian ini disajikan pada tabel 1 berikut.

Tabel 1. Cross Validasi dari Data Keuangan

Data	Training	Validasi	Testing
IHSG sebelum covid-19	508	109	109
IHSG setelah covid-19	224	48	48

B. Hasil

Penelitian ini menggunakan lebih banyak persentase untuk data *training*, hal ini dilandasi karena untuk melatih jaringan dari BPNN dibutuhkan data yang banyak. Sehingga peneliti menggunakan persentase *training* sebesar 70% dari keseluruhan data yang akan diteliti. Semua tahapan dari pembentukan arsitektur BPNN individual dilakukan menggunakan software MATLAB.

Langkah pertama dalam teknik ensemble adalah membangkitkan prediktor jaringan. Pembangkitan prediktor jaringan dilakukan dengan menjalankan jaringan-jaringan individual dari BPNN. Prediktor jaringan kemudian diukur menggunakan kinerja statistik masing-masing jaringan individual BPNN. Kinerja statistik jaringan didasarkan pada arsitektur jaringan tersebut. Perbedaan arsitektur didasarkan pada hidden layer, yaitu 3-3-1; 3-6-1; dan 3-9-1. Proses optimisasi dilakukan terhadap data IHSG sebelum dan setelah covid-19. Data akan dibagi menjadi tiga yaitu *training*, *validasi*, dan *testing*. Setelah proses dilakukan, jaringan individual akan dipilih menggunakan pendekatan *Keep The Best* (KTB), dengan melihat pada evaluasi statistik berdasarkan penurunan error saat proses *training*. Berikut disajikan dengan nilai evaluasi statistik.

Tabel 2. Kinerja Jaringan Individual NN

Data	Arsitektur Jaringan	Training		Validasi		Testing	
		MSE	MAE	MSE	MAE	MSE	MAE
IHSGBelum	3-3-1	0.0054	0.0544	0.0170	0.1017	0.0089	0.0758
		0.0054	0.0547	0.1443	0.2677	0.0071	0.0658
		0.0055	0.0552	0.0143	0.0911	0.0413	0.1351
		0.0054	0.0543	0.0181	0.1059	0.0079	0.0686
		0.0057	0.0556	0.0148	0.0952	0.0085	0.0729
		0.0054	0.0543	0.0124	0.0806	0.0173	0.1028
		0.0053	0.0540	0.0158	0.0962	0.0077	0.0710
	3-6-1	0.0055	0.0547	0.0170	0.1015	0.0080	0.0704
		0.0054	0.0547	0.0123	0.0813	0.0078	0.0692
		0.0055	0.0547	0.0140	0.0890	0.0079	0.0716
		0.0055	0.0550	0.0122	0.0817	0.0072	0.0661
		0.0058	0.0567	0.0118	0.0829	0.0080	0.0706
	3-9-1	0.0053	0.0541	0.0153	0.0979	0.0083	0.0713
		0.0054	0.0545	0.0121	0.0858	0.0063	0.0618
		0.0054	0.0545	0.0175	0.1023	0.0089	0.0736
0.0039		0.0452	0.0226	0.1156	0.0283	0.1211	
	0.0039	0.0452	0.0218	0.1114	0.0516	0.1766	
3-3-1	0.0045	0.0487	0.0221	0.1014	0.0152	0.0896	
	0.0046	0.0494	0.0254	0.1153	0.0287	0.1400	
	0.0045	0.0477	0.0313	0.1468	0.0337	0.1428	
	0.0047	0.0503	0.0076	0.0633	0.0254	0.1088	
	0.0046	0.0492	0.0097	0.0719	0.0253	0.1154	
IHSGBelum	3-6-1	0.0045	0.0484	0.0153	0.0846	0.0199	0.0991
		0.0046	0.0488	0.0150	0.0870	0.0162	0.0938
		0.0040	0.0462	0.0128	0.0767	0.0321	0.1478
		0.0046	0.0495	0.0073	0.0163	0.0264	0.1027
		0.0045	0.0495	0.0138	0.0744	0.0205	0.1002
3-9-1	0.0037	0.0439	0.0097	0.0577	0.0221	0.1003	
	0.0043	0.0479	0.0090	0.0589	0.0086	0.0578	
	0.0136	0.0808	6.7559e-04	0.0155	0.0046	0.0404	

Tabel 2 memperlihatkan kinerja dari masing-masing jaringan BPNN yang dijalankan secara individual. Masing-masing jaringan ditraining, divalidasi dan ditesting sebanyak lima kali. Kemudian dengan menggunakan pendekatan KTB setiap arsitektur berbeda dipilih satu jaringan yang memberikan kinerja terbaik berdasarkan kinerja jaringan dengan melihat nilai MSE dan MAE. Berdasarkan proses yang telah dilakukan pada saat training, masing-masing arsitektur memberikan waktu training yang berbeda-beda. Namun dapat disimpulkan bahwa semakin banyak unit pada hidden layer maka semakin banyak waktu yang dibutuhkan pada saat proses training dilakukan. Selain itu, pada beberapa jaringan hasil validasi dan testing memberikan kinerja yang tidak sesuai dengan kinerja saat proses training. Hal ini dikhawatirkan terjadi karena jaringan individual terjadi *overfitting*.

Berdasarkan tabel di atas maka dapat di ringkas tampilan tabel menjadi bentuk berikut setelah dilakukan pemilihan berdasarkan pendekatan KTB dari kinerja masing-masing jaringan individual.

Tabel 3. Kinerja Jaringan Individual NN yang dinilai berdasarkan pendekatan KTB

Data	Arsitektur Jaringan	Training		Validasi		Testing	
		MSE	MAE	MSE	MAE	MSE	MAE
IHSGBelum	3-3-1	0.0054	0.0543	0.0181	0.1059	0.0079	0.0686
	3-6-1	0.0053	0.0540	0.0158	0.0962	0.0077	0.0710
IHSGBelum	3-9-1	0.0053	0.0541	0.0153	0.0979	0.0083	0.0713
	3-3-1	0.0039	0.0452	0.0226	0.1156	0.0283	0.1211
IHSGBelum	3-6-1	0.0040	0.0462	0.0128	0.0767	0.0321	0.1478
	3-9-1	0.0037	0.0439	0.0097	0.0577	0.0221	0.1003

Penelitian ini menggunakan teknik ensemble yang dilakukan dengan pendekatan *simple averaging* yang kemudian digunakan sebagai sampel baru. Penelitian menggunakan dua pendekatan, pertama menggabungkan jaringan individual BPNN yang telah dilatih menggunakan bobot berbeda; kedua, menggabungkan arsitektur jaringan individual BPNN yang berbeda dalam suatu ensemble. Hasil teknik ensemble disajikan pada tabel berikut.

Tabel 4. Hasil Ansambel dengan Bobot Awal Berbeda dengan Arsitektur dan Data yang Sama

Data	Metode	Training		Validasi		Testing	
		MSE	MAE	MSE	MAE	MSE	MAE
IHSGBelum	Individual	0.0053	0.0541	0.0153	0.0979	0.0083	0.0713
IHSGBelum	Ansambel	0.0066	0.0586	0.0095	0.0743	0.0063	0.0601
IHSGBelum	Individual	0.0037	0.0439	0.0097	0.0577	0.0221	0.1003
IHSGBelum	Ansambel	0.0027	0.0371	0.0019	0.0322	0.0069	0.0653

Tabel 4 menyajikan evaluasi statistik dari masing-masing kelompok data. Evaluasi statistik berdasarkan jaringan individual BPNN dibandingkan dengan teknik ensemble yang digunakan yang dipilih menggunakan pendekatan KTB. KTB dipilih dengan melihat pada error yang terkecil diberikan oleh sejumlah jaringan individual BPNN yang dijalankan untuk diprediksi.

Tabel 4 menunjukkan bahwa jaringan individual BPNN yang telah terpilih menggunakan pendekatan KTB diperoleh bahwa jaringan BPNN yang menjadi lebih kompleks. Hal ini dikarenakan adanya peningkatan pada unit-unit tersembunyi serta kinerja jaringan untuk kelompok training dengan pendekatan KTB menurun saat mengukur error. Tabel 5 juga menunjukkan bahwa optimisasi BPNN menggunakan metode ensemble memberikan kinerja yang baik dibandingkan jaringan individual BPNN yang diukur melalui evaluasi statistik serta konsisten memberikan kinerja yang baik tidak hanya pada saat dilakukan data training melainkan juga untuk data validasi dan data testing.

Tabel 5. Hasil Ansambel dengan Menggabungkan Arsitektur dan Bobot berbeda

Data Keuangan	Arsitektur Jaringan	Training		Validasi		Testing	
		MSE	MAE	MSE	MAE	MSE	MAE
IHSG-Belum	3-3-1	0.0061	0.0554	0.0117	0.0772	0.0066	0.0584
	3-6-1	0.0061	0.0556	0.0095	0.0696	0.0057	0.0539
	3-9-1	0.0060	0.0553	0.0094	0.0695	0.0059	0.0551
IHSG-Setelah	3-3-1	0.0052	0.0520	0.0185	0.0945	0.0319	0.1323
	3-6-1	0.0048	0.0504	0.0108	0.0689	0.0135	0.0806
	3-9-1	0.0044	0.0476	0.0018	0.0258	0.0046	0.0492

Tabel 5 merupakan teknik ansambel yang dilakukan dengan menggabungkan arsitektir dan bobot berbeda dari masing-masing jaringan individual BPNN. Tabel 6 memperlihatkan bahwa teknik ensemble konsisten menurunkan error dalam evaluasi statistik untuk data *training*, validasi dan *testing*.

4. Kesimpulan

Pergerakan laju IHSG yang volatil diakibatkan pademi covid-19, membuat sulitnya pengelola dana untuk memperkirakan dana investasi yang dimiliki. Karena data yang volatil akan bergerak secara berfluktuatif sehingga akan sulit untuk diprediksi. Prediksi dilakukan untuk membantu para investor untuk dapat mengambil tindakan yang tepat terhadap investasi yang dimiliki. Dengan tujuan untuk memperkecil ersiko dan memperoleh keuntungan yang optimal. Pada penelitian ini prediksi dilakukan menggunakan BPNN yang dioptimisasi menggunakan teknik ansambel. Hasil penelitian menunjukkan teknik ansambel memberikan hasil evaluasi statistik yang signifikan dengan penurunan error. Sehingga prediksi yang diperoleh lebih optimal

Daftar Pustaka

Dyah Puspitaningrum (2006) *Jaringan Syaraf Tiruan*. Jakarta: Andi.

Efek, B., Pada, I. and Pandemi, M. (2021) ‘Vol : 9, No : 1, 2021 Jurnal Akuntansi dan Perpajakan Indonesia UNIMED’, 19(September 2020).

Jeong, D. Il and Kim, Y. O. (2005) ‘Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction’, *Hydrological Processes*, 19(19), pp. 3819–3835. doi: 10.1002/hyp.5983.

Kannan, K. S. *et al.* (2010) ‘Financial Stock Market Forecast using Data Mining Techniques’, (March), pp. 15–20.

Kourentzes, N., Barrow, D. K. and Crone, S. F. (2014) ‘Neural network ensemble operators for time series forecasting’, *Expert Systems with Applications*, 41(9), pp. 4235–4244. doi:

10.1016/j.eswa.2013.12.011.Melin, P. *et al.* (2020) ‘Multiple ensemble neural network models with fuzzy response aggregation for predicting covid-19 time series: The case of mexico’, *Healthcare (Switzerland)*, 8(2). doi: 10.3390/healthcare8020181.

Naftaly, U., Intrator, N. and Horn, D. (1997) ‘Optimal ensemble averaging of neural networks’, *Network: Computation in Neural Systems*, 8(3), pp. 283–296. doi: 10.1088/0954-898x/8/3/004.

Sciences, H. (2016) ‘濟無No Title No Title No Title’, 4(1), pp. 1–23.

Siwek, K., Osowski, S. and Szupiluk, R. (2009) ‘Ensemble neural network approach for accurate load forecasting in a power system’, *International Journal of Applied Mathematics and Computer Science*, 19(2), pp. 303–315. doi: 10.2478/v10006-009-0026-2.

Suryaputri, R. V. and Kurniawati, F. (2020) ‘Analisis ISSI, IHSG, dan nilai tukar rupiah selama pandemi COVID-19’, *Prosiding Konferensi Nasional Ekonomi Manajemen dan Akuntansi (KNEMA)*, 1177, pp. 1–17.

Yang, X. *et al.* (2019) ‘Novel financial capital flow forecast framework using time series theory and deep learning: A case study analysis of Yu’e Bao transaction data’, *IEEE Access*, 7, pp. 70662–70672. doi: 10.1109/ACCESS.2019.2919189.

Yin, Y. *et al.* (2017) ‘Collaborative QoS Prediction for Mobile Service with Data Filtering and SlopeOne Model’, *Mobile Information Systems*, 2017(2). doi: 10.1155/2017/7356213.

Zhang, P. G. (2003) ‘Time series forecasting using a hybrid ARIMA and neural network model’, *Neurocomputing*, 50, pp. 159–175. doi: 10.1016/S0925-2312(01)00702-0.