

OPTIMALISASI PREDIKSI SAHAM APPLE DAN SAMSUNG DENGAN ALGORITMA BPNN

Atika Mutiarachim¹, Yupie Kusumawati², Nurchayati³, Aulia Indriawati⁴

1,4) Program Studi Bisnis Digital, Fakultas Ekonomika dan Bisnis, Universitas 17 Agustus 1945 Semarang

2) Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro Semarang

3) Program Studi Akuntansi, Fakultas Ekonomika dan Bisnis, Universitas 17 Agustus 1945 Semarang

Article Info

Article history:

Received: 03 Juni 2025

Revised: 25 Juni 2025y

Accepted: 07 Juli 2025

ABSTRACT

Abstrak

Pasar saham global khususnya bidang teknologi mengalami volatilitas yang signifikan, dengan saham Apple Inc. dan Samsung Electronics Co., Ltd sebagai pemain utama. Prediksi signifikan sangat diperlukan untuk mengurangi resiko investasi. Penelitian ini menganalisis dan membandingkan kinerja *Backpropagation Neural Network (BPNN)* dalam memprediksi pergerakan saham Apple dan Samsung. Dataset publik diperoleh dari Kaggle, saham Samsung dengan 6128 data periode 4 Januari 2000 sampai 13 Juni 2024 dan saham Apple dengan 2476 data periode 2 Januari 2014 sampai 31 Oktober 2023. Metode BPNN diterapkan dengan optimasi parameter learning rate, momentum, dan *training cycle*, pembagian data 10-fold cross validation, evaluasi nilai Root Mean Square Error (RMSE). Hasil terbaik menunjukkan konfigurasi optimal diperoleh dari learning rate 0.1, momentum 0.9, error epsilon 1.0E-4 dan *training cycle* 60. Nilai RMSE terbaik saham Apple 0.802 ± 0.263 dengan akurasi 99.85%, dan pada saham Samsung RMSE terbaik 399.806 ± 102.670 dengan akurasi 99.36%. Penelitian membuktikan BPNN dengan pola 0.1-0.9-60 sangat efektif memprediksi harga Close sehingga mampu memberikan kontribusi signifikan bagi investor dalam melakukan evaluasi investasi sebagai strategi meminimalisir resiko saham.

Kata Kunci: Backpropagation Neural Network, Stock Price Prediction, Apple, Samsung, Machine Learning

Abstract

The global technology stock market experiences significant volatility with Apple Inc. and Samsung Electronics Co., Ltd. as major players. This research analyzes and compares Backpropagation Neural Network (BPNN) performance in predicting Apple and Samsung stock movements. Datasets were obtained from Kaggle: Samsung stock price with 6128 data from January 4, 2000- until June 13, 2024 and Apple stock price with 2476 data from January 2, 2014 until October 31, 2023. The BPNN method was applied with parameter optimization of learning rate, momentum and training cycle s. Data splitting used 10-fold cross validation with Root Mean Square Error (RMSE) evaluation. Results show optimal configuration with learning rate 0.1, momentum 0.9, error epsilon 1.0E-4 and training cycle 60. Best RMSE values were 0.802 ± 0.263 for Apple and 399.806 ± 102.670 for Samsung. Prediction accuracy reached 99.85% for Apple and 99.36% for Samsung. The RMSE difference was influenced by varying dataset sizes. The research proves BPNN with this configuration is highly effective for predicting technology stock closing prices, providing significant contribution for investors in investment evaluation and risk reduction strategies.

Keywords: Backpropagation Neural Network, Stock Price Prediction, Apple, Samsung, Machine Learning

Djtechno: Jurnal Teknologi Informasi oleh Universitas Dharmawangsa Artikel ini bersifat open access yang didistribusikan di bawah syarat dan ketentuan dengan Lisensi Internasional Creative Commons Attribution NonCommercial ShareAlike 4.0 ([CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/)).



Corresponding Author:

E-mail: amutiarachim@gmail.com

1. PENDAHULUAN

Pasar saham teknologi global mengalami volatilitas yang signifikan, terutama pada dekade terakhir. Apple Inc. dan Samsung Electronics Co., Ltd., menjadi dua pemain utama yang mencerminkan dinamika industry teknologi secara keseluruhan. Kedua perusahaan ini memiliki karakteristik bisnis dan respon pasar yang berbeda. Apple dengan ekosistem tertutup dan fokus pada integrasi vertikal, sementara Samsung dengan diversifikasi produk yang lebih luas serta ketergantungan pada rantai pasok global yang kompleks. Fluktuasi harga saham Apple dan Samsung menunjukkan pola kompleks yang dipengaruhi berbagai faktor ekonomi, sentiment pasar dan dinamika industry yang berbeda di ekosistem masing-masing [1], [2]. Kondisi ini menciptakan pola pergerakan saham yang unik, menantang dan cenderung tidak mudah untuk diprediksi. Pendekatan tradisional kurang dapat mengatasi permasalahan prediksi secara signifikan. Pemanfaatan analisis *big data*, kecerdasan buatan, *machine learning* dan data mining, menggunakan berbagai algoritma prediksi, memberikan peluang baru untuk meningkatkan akurasi prediksi dengan mempertimbangkan kompleksitas pola data historis dan faktor eksternal yang mempengaruhi kedua saham tersebut [3].

Prediksi harga saham yang tepat sangat relevan dan penting, menjadi penelitian krusial bagi investor dan analis pasar. Pemanfaatan teknologi sangat tepat dalam membantu pelaku investasi dalam mengobservasi pergerakan pasar, sehingga berdampak pada kemudahan dalam evaluasi investasi, menghindari kerugian dan memperoleh keuntungan maksimal [4]. Akar masalahnya adalah bagaimana membantu investor dan pelaku pasar untuk melakukan prediksi harga saham sehingga dapat mengurangi risiko dan meningkatkan keberhasilan investasi.

Penelitian [5] menggunakan data historis saham PT. Bank Jago Tbk. (ARTO) periode 6 November 2019 sampai 27 Oktober 2023, yang diambil dari website yahoo.finance.com. Total 969 data dengan 6 atribut terdiri dari *date*, *open*, *high*, *low*, *close* dan *volume*. Pembagian data menggunakan metode *split data* 60:40, hasil prediksi Linear Regression (LR) RMSE 228.130, Neural Network (NN) menghasilkan RMSE lebih rendah yaitu 180.745, sehingga pada penelitian ini NN direkomendasikan untuk memprediksi harga saham.

Penelitian [6] membandingkan kinerja *Artificial Neural Network* (ANN) dengan *Random Forest* (RF) dalam melakukan prediksi data saham lima perusahaan yaitu Nike, Goldman Sachs, JP Morgan and Co., Johnson & Johnson dan Pfizer Inc. Indikator evaluasi berdasarkan nilai RMSE, MAPE dan MBE dimana nilai terendah menunjukkan model paling efisien dalam memprediksi harga Close saham. Hasil prediksi menunjukkan ANN menghasilkan nilai eror lebih rendah daripada RF dengan RMSE (0.42), MAPE (0.77) dan MBE (0.013).

Penelitian [7] dengan data saham keju dari *Indonesian Stock Exchange* (IDX) periode 15 November 2019 sampai 8 Juni 2021 dengan atribut *date*, *previous*, *high*, *low*, *close* dan *volume*, dengan *pre-processing cleaning* dan *scaling*, membandingkan prediksi LR, LSTM dan GRU. Hasil terbaik diperoleh GRU dengan RMSE terendah 0.034, dilanjutkan LSTM dengan RMSE 0.048 dan LR dengan RMSE 4.621. Penelitian [8] menggunakan data prediksi saham Coca-Cola dengan metode LR, LSTM dan GRU, dengan pembagian *split data* 80:20, dengan *window-width* 3 RMSE 0.64, *window-width* 4 RMSE 0.57 dan *window-width* 5 RMSE 0.48.

Analisis perbandingan algoritma prediksi data harga saham LQ45 PT Bank Mandiri Sekuritas (BMRI) pada penelitian [9], membandingkan *performance* LR dan NN. Data sejumlah. Pengujian LR dilakukan dengan membandingkan metode ekstraksi fitur M5 Prime, Greedy, T-Test dan Iterative T-Test. Metode NN membandingkan hasil RMSE berdasarkan perhitungan *learning rate* dan *momentum* dari 0.1 sampai 0.9, dengan *training cycle* 300. Hasil menunjukkan LR dengan ekstraksi fitur M5 Prime memperoleh RMSE 0.052, sedangkan NN dengan *learning rate* dan *momentum* 0.9 menghasilkan RMSE yang lebih baik yaitu 0.034.

Penelitian [10] memprediksi Indeks Harga Saham Gabungan (IHSG) dengan 757 data periode 8 Mei 2018 sampai dengan 7 Mei 2021, yang diperoleh dari website finance.yahoo.com. Preprocessing menghasilkan data yang tersisa sebanyak 724, dibagi dengan metode split 70:30 dan diuji dengan metode BPNN dengan membandingkan kondisi *training cycle* dari 10 sampai 100. Hasil terbaik diperoleh pada *training cycle* 100 dengan hasil RMSE 0.010. Penelitian [11] menganalisis harga saham Bank BCA menggunakan BPNN, dengan optimasi *Particle Swarm Optimization* (PSO) untuk meningkatkan akurasi dan kecepatan konvergensi model. Evaluasi dinilai dari perolehan *Squared Error* (SE) dan RMSE, dengan perolehan SE 0.325 ± 0.565 dan RMSE 0.570

± 0.000 menandakan kesalahan prediksi rendah, model memiliki akurasi tinggi dengan prediksi yang mendekati nilai aktual.

Penelitian [12] menguji data IHSG periode 1 Maret 2017 sampai dengan 28 Februari 2020, dan data setelah Covid 19 sejak 1 Maret 2019 sampai dengan 30 Juni 2021 yang diperoleh dari yahoo.finance menggunakan teknik ensamble. Pembagian data 70% *training*, 15% validasi dan 15% *testing*. Hasil menunjukkan teknik *ensemble* dan BPNN konsisten menghasilkan nilai eror yang rendah pada seluruh data.

Penelitian [13] menganalisis prediksi PT. Bank Central Asia pasca *stock split* dengan algoritma BPNN, inisialisasi bobot dan bias awal menggunakan algoritma Nguyen-Widrow dengan fungsi aktivasi sigmoid biner. Variabel yang digunakan harga pembukaan, harga tertinggi, harga terendah, volume transaksi, inflasi, suku bunga, kurs rupiah dengan variable target harga. Percobaan menggunakan 24 kombinasi arsitektur jaringan yang berbeda dengan presentase data *training* 80:20, 70:30 *epoch* 1000, neuron *hidden* sebanyak 5, 10, 15 dan 20, *learning rate* 0.01, 0.1, 0.5. Arsitektur jaringan terbaik 7-20-1 menghasilkan prediksi paling akurat dengan nilai MAPE *training* 3.7568% dan *testing* 7.7012%.

Penelitian [14] mengukur risiko investasi saham PT Aneka Tambang Tbk (ANTAM) dengan metode BPNN yang dioptimasi inisialisasi bobot Nguyen Widrow. Total 1340 data harga saham periode 2 Januari 2018 sampai 10 Juli 2023, pembagian data 80:20, membandingkan komponen nilai arsitektur, *momentum* dan *learning rate*. Hasil terbaik diperoleh dari inisialisasi bobot Nguyen Widrow (5-11-1) mencapai akurasi prediksi 98.0053% dengan MAPE 1.9947%.

Penelitian [15] melakukan prediksi harga penutupan saham harian PT. Bank Rakyat Indonesia (Persero) Tbk, dataset BBRI periode 1 Agustus sampai 31 Agustus 2023. Hasil terbaik menggunakan BPNN dengan arsitektur (5,3,1), *learning rate* 0.01, menghasilkan nilai MAPE 0.8193%.

Terdapat beragam metode NN [16], penelitian dilakukan dengan metode *Backpropagation Neural Network* (BPNN) karena lebih sederhana dalam pengoperasian, *overhead* kalkulasi yang kecil dan memiliki paralelisme yang kuat [17], [18], [19], [20]. Berbagai penelitian telah menggunakan BPNN untuk analisis prediksi harga saham namun belum ada studi yang secara khusus membandingkan saham Apple dan Samsung menggunakan metode BPNN, hal tersebut menjadi dasar *research gap* dalam penelitian

ini untuk memberikan analisis komparatif yang komprehensif, membandingkan performa dalam prediksi pergerakan saham Apple dan Samsung, mengidentifikasi pola BPNN yang paling optimal dalam melakukan prediksi pada masing-masing saham.

2. METODE PENELITIAN

Dataset pada penelitian diperoleh dari data *public* Kaggle. Dataset Samsung stock price berisikan informasi perubahan harga saham Samsung sejak 4 Januari 2000 sampai dengan 13 Juni 2024, dengan jumlah data 6128, link dataset <https://www.kaggle.com/datasets/mayankanand2701/samsung-stock-price-dataset>. Dataset Apple stock price berisi 2476 data sejak 2 Januari 2014 sampai 31 Oktober 2023, link dataset <https://www.kaggle.com/datasets/rafsunahmad/apple-stock-price>. Atribut pada kedua dataset yang digunakan dalam penelitian adalah tanggal, harga pembukaan (Open), harga tertinggi hari itu (High), harga terendah hari itu (Low), harga penutupan (Close), harga penutupan yang disesuaikan (Adj Close), dan volume perdagangan. Tahap *preprocessing* dilakukan untuk memastikan data konsisten, tidak mengandung *missing value* dan *outlier*.

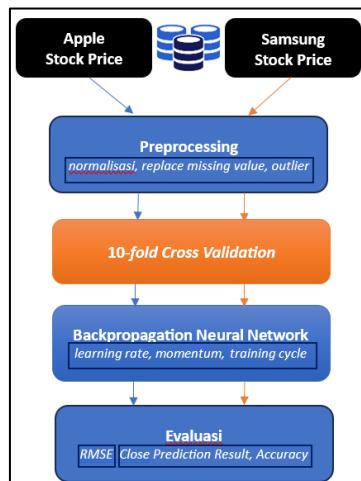
Table 1. Samsung stock price

No	Date	Open	High	Low	Close	Adj Close	Volume
1	1/4/2000	6000	6110	5660	6110	4449.71	74195000
2	1/5/2000	5800	6060	5520	5580	4063.729	74680000
3	1/6/2000	5750	5780	5580	5620	4092.86	54390000
4	1/7/2000	5560	5670	5360	5540	4034.599	40305000
5	1/10/2000	5600	5770	5580	5770	4202.098	46880000

Table 2. Apple stock price

No	Date	Open	High	Low	Close	Adj Close	Volume
1	1/2/2014	19.84571	19.89393	19.715	19.75464	17.31873	234684800
2	1/3/2014	19.745	19.775	19.30107	19.32071	16.9383	392467600
3	1/6/2014	19.19464	19.52857	19.05714	19.42607	17.03068	412610800
4	1/7/2014	19.44	19.49857	19.21143	19.28714	16.90888	317209200
5	1/8/2014	19.24321	19.48429	19.23893	19.40929	17.01596	258529600

Pengujian BPNN dilakukan dengan melakukan percobaan berdasarkan pembagian data, nilai *error epsilon*, *learning rate*, *momentum* dan *training cycle*. Pembagian 10-fold cross validation memberikan hasil terbaik.



Gambar 1. Metode Penelitian

Nilai *learning rate* diuji dalam rentang 0.1-0.9, *momentum* dievaluasi pada rentang 0.01-0.9 dan variasi *training cycle* diuji dalam rentang 10 hingga 100 iterasi untuk menentukan konfigurasi parameter yang memberikan tingkat eror minimum. Evaluasi berdasarkan nilai eror RMSE terendah akan menjadi acuan untuk melakukan perbandingan harga Close Actual dengan harga Close Prediction hasil prediksi BPNN.

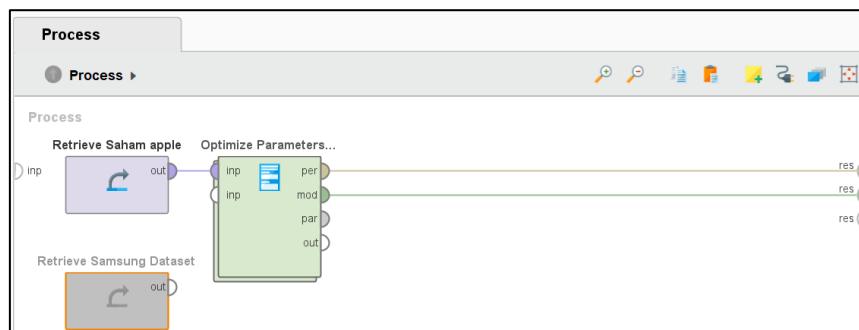
3. HASIL DAN PEMBAHASAN

Pengujian mulai dari *preprocessing data* sampai evaluasi menggunakan *tool Altair AI Studio*. Operator *optimize parameter grid* digunakan untuk memasukkan nilai minimum dan maksimum dari *leaning rate*, *momentum*, dan *training cycle*. Penelitian terdahulu menunjukkan *leaning rate* 0.1, *momentum* 0.9 menghasilkan nilai eror rendah. Pengujian dilakukan dengan nilai *error epsilon* 1.0E-4 dengan nilai *training cycle* yang berbeda. Kombinasi parameter terbaik adalah yang menghasilkan nilai eror rendah.

Dataset *preprocessing* dengan memastikan tidak ada *outlier* dan *missing value*, kemudian di normalisasi menggunakan *Z-transformation* untuk standarisasi fitur. Pengujian BPNN menggunakan 1 sampai 6 *hidden layer*. Arsitektur 1 *hidden layer* dengan 2 *neuron* yang dipilih, berdasarkan pengujian konfigurasi optimal. Nilai RMSE digunakan sebagai *loss function* dan metrik evaluasi karena *interpretable*, sensitif terhadap *outlier*.

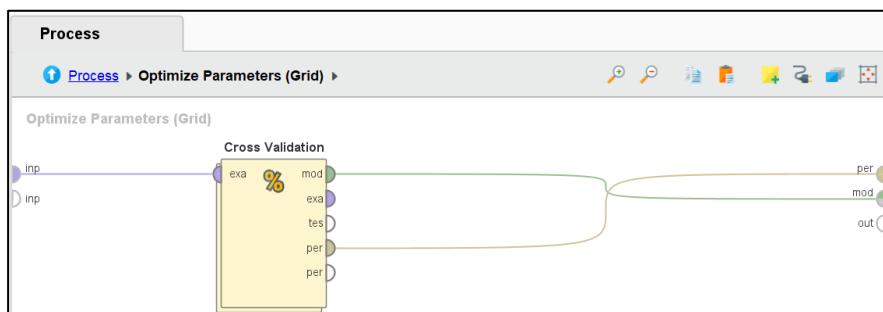
dan memberikan hasil dalam satuan asli. Pembagian data menggunakan *10-fold cross validation* dengan *sampling type automatic* untuk memastikan validasi yang *robust*.

Penggunaan *learning rate* yang semakin besar berpengaruh pada proses *training* yang semakin cepat [21]. Momentum bertujuan untuk menambahkan sebagian kecil bobot dari pembaruan bobot sebelumnya. *Training cycle* menentukan jumlah pelatihan yang dilakukan pada jaringan saraf untuk mendapatkan nilai eror terendah. Parameter optimal diperoleh melalui *grid search* dengan *learning rate* 0.1, *momentum* 0.9, *error epsilon* 1.0E-4 dan *training cycle* 60.

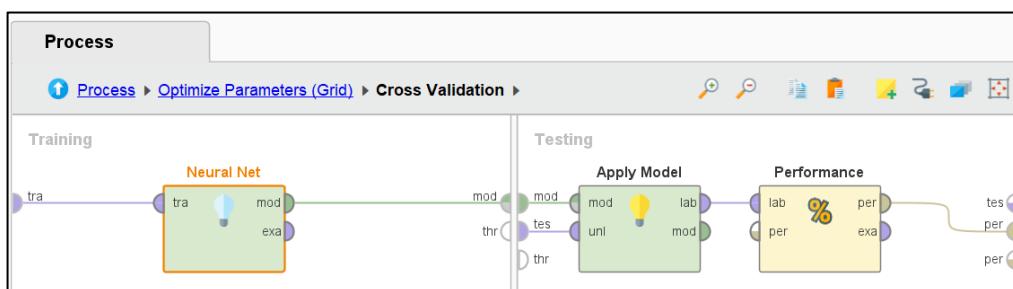


Gambar 2. Proses Optimize Parameter

Proses dilakukan secara bertahap pada masing-masing dataset, dengan melakukan pengujian pada *training cycle* 10 sampai 100. Pembagian data menggunakan *10-fold cross validation*.



Gambar 3. Pembagian data 10-fold cross validation



Gambar 4. Proses Algoritma BPNN

Hasil pengujian berupa nilai RMSE yang merupakan ukuran kinerja yang didefinisikan sebagai akar kuadrat dari ekspektasi selisih kuadrat antara nilai estimasi dan nilai aktual. Semakin rendah RMSE maka semakin baik metode tersebut menghasilkan nilai Close prediksi [2], [22].

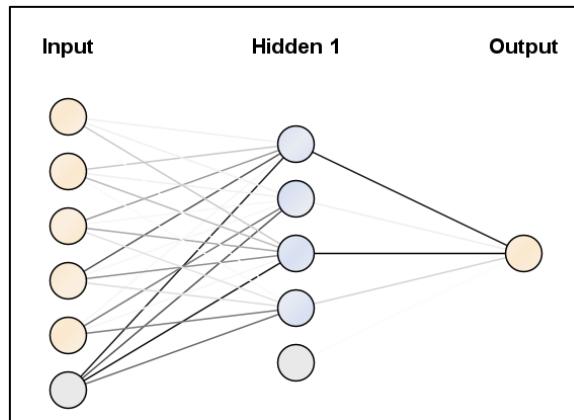
Table 3. Hasil Pengujian Data

BPNN 10-fold Cross Validation <i>Training cycle</i>	RMSE	
	Dataset Apple stock price	Dataset Samsung stock price
10	1.256 ± 0.533	453.095 ± 121.109
20	0.886 ± 0.318	407.479 ± 110.883
30	0.843 ± 0.283	404.631 ± 106.789
40	0.822 ± 0.267	402.069 ± 104.550
50	0.805 ± 0.258	400.012 ± 103.256
60	0.802 ± 0.263	399.806 ± 102.670
70	0.802 ± 0.263	399.806 ± 102.670
80	0.802 ± 0.263	399.806 ± 102.670
90	0.802 ± 0.263	399.806 ± 102.670
100	0.802 ± 0.263	399.806 ± 102.670

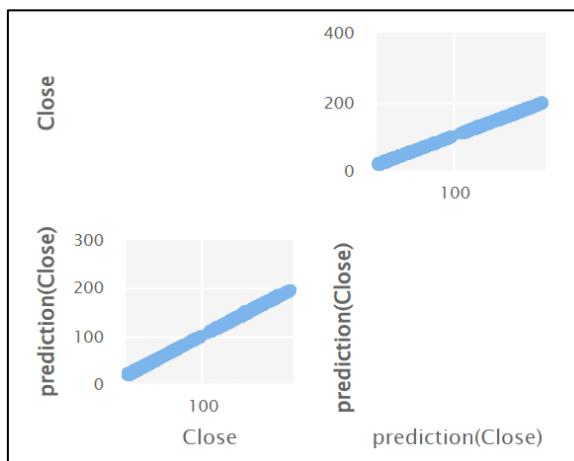
Percobaan dilakukan dengan mengubah nilai *learning rate* 0.1 sampai 0.9, eror terendah diperoleh dari learning rate 0.1. Momentum diuji dari nilai 0,01 sampai 0,9, nilai eror terendah dihasilkan momentum 0.9. Percobaan selanjutnya dengan mengubah nilai *training cycle* dari 10 sampai dengan 100. Hasil nilai 60 sampai 100 dihasilkan nilai eror terendah dengan nilai yang sama yaitu 0.802 ± 0.263 untuk RMSE Apple stock price dan 399.806 ± 102.670 untuk RMSE Samsung stock price. *Training cycle* 60 dipilih karena semakin banyak training dilakukan maka berdampak pada kebutuhan waktu eksekusi yang lebih panjang. Perbedaan nilai RMSE dipengaruhi oleh jumlah data yang digunakan, dimana data Samsung jauh lebih banyak dibandingkan data Apple.

Table 4. Perhitungan Akurasi Close Prediction Apple Stock Price

No	Date	Close (Actual)	Close (Prediction)	Percentase
1	21-Jan-2014	19.60964	19.7153481	99.46%
2	23-Jan-2014	19.86357	19.79228236	100.36%
3	31-Jan-2014	17.87857	17.98083147	99.43%
4	10-Feb-2014	18.8925	19.06455288	99.10%
5	4-Mar-2014	18.97286	19.40795248	97.76%
....
2476	23-Oct-2023	173	171.974	100
Akurasi:				99.85%



Gambar 5 Arsitektur BPNN Apple Stock Price



Gambar 6 Perbandingan Close Actual dan Close Prediction BPNN Apple Stock Price

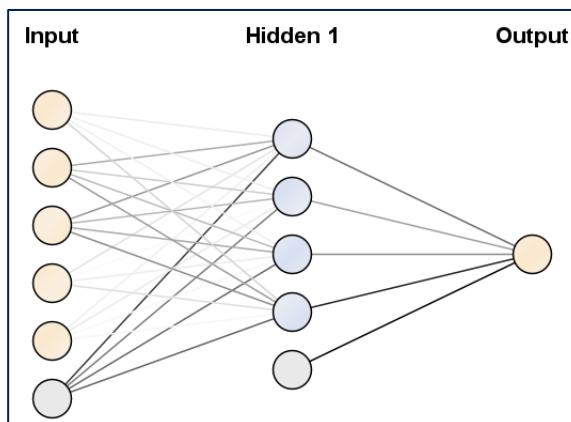


Gambar 7 Grafik BPNN Apple Stock Price

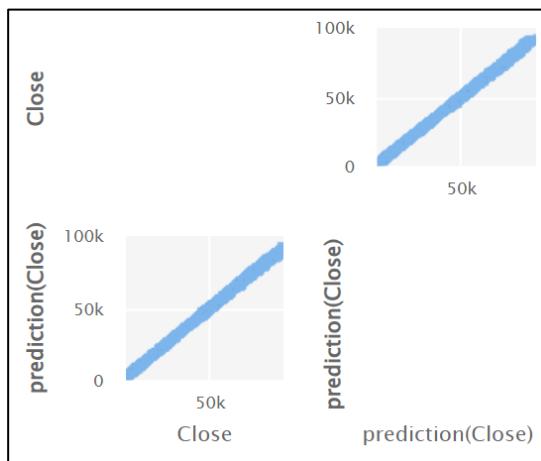
Gambar 6 dan 7 menunjukkan grafik nilai Close Prediction hasil prediksi BPNN pola 0.1-0.9-60 pada Apple stock price sangat mendekati nilai Close Actual yang sudah ada pada dataset, menunjukkan tingkat akurasi yang sangat baik. Akurasi dihitung sebagai rata-rata dari selisih persentase nilai prediksi terhadap nilai aktual pada seluruh titik data. Akurasi yang diperoleh dari hasil prediksi dataset Apple yaitu 99.85%.

Table 5. Perhitungan Akurasi Close Prediction Samsung Stock Price

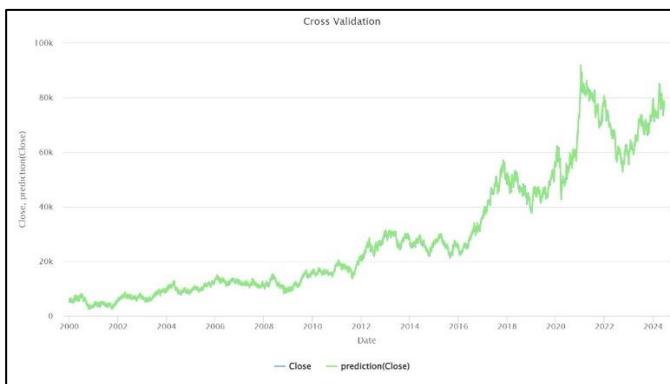
No	Date	Close (Actual)	Close (Prediction)	Percentase
1	6-Jan-2000	5620	5899.54	95.26%
2	10-Jan-2000	5770	5889.234	97.98%
3	7-Feb-2000	5240	5410.711	96.85%
4	1-Mar-2000	5120	5296.941	96.66%
5	9-Mar-2000	5620	6006.591	93.56%
....
6128	13-Jun-2024	78600	79084.66	99.39%
Akurasi:				99.36%



Gambar 8 Arsitektur BPNN Samsung Stock Price



Gambar 9 Perbandingan Close Actual dan Close Prediction BPNN Samsung Stock Price



Gambar 10 Grafik BPNN Samsung Stock Price

Gambar 9 dan 10 menunjukkan grafik nilai Close Prediction hasil prediksi BPNN pola 0.1-0.9-60 pada Samsung stock price sangat mendekati nilai Close Actual yang sudah ada pada dataset, menunjukkan tingkat akurasi yang sangat baik, sesuai perhitungan akurasi pada tabel 5 yaitu 99.36%.

4. SIMPULAN

Hasil RMSE terbaik diperoleh dari algoritma BPNN dengan *learning rate* 0.1, *momentum* 0.9, *error epsilon* 1.0E-4 dengan nilai *training cycle* 60 sampai 100, pada penelitian ini dipilih *training cycle* 60 untuk meminimalisir kebutuhan waktu eksekusi. Nilai RMSE terbaik untuk Apple stock price adalah 0.802 ± 0.263 dan untuk Samsung stock price adalah 399.806 ± 102.670 . Hasil perhitungan prediksi BPNN dengan pola 0.1-0.9-60 tersebut menghasilkan akurasi yang tinggi yaitu 99.85% pada Apple stock price dan 99.36% pada Samsung stock price. Nilai akurasi yang hampir mendekati 100% menunjukkan harga Close prediction yang dihasilkan dari metode BPNN dengan pola 0.1-0.9-60 sangat mendekati Close Actual.

REFERENCES

- [1] H. Albasoos and N. Al-Musallami, “The conflict between Apple and Samsung over Patents and Copyrights,” vol. 2, no. 3, pp. 1–7, 2020, doi: 10.36096/brss.v2i3.206.
- [2] Susbiyantoro, Caroline, J. Aninam, and A. R. Nugraha, “Analisis Perbandingan Merek Smartphone Apple dan Samsung pada Mahasiswa Fakultas Ekonomi Universitas Swasta di Jakarta,” *Jurnal EMT KITA*, vol. 7, no. 4, pp. 950–963, Oct. 2023, doi: 10.35870/emt.v7i4.1547.
- [3] A. Mutiarachim, “Integration of Artificial Intelligence and Big Data Analytics in Customer-Centric Organizations,” in *INTELLIGENT TRANSFORMATION: AI's Role in Business, Governance, Learning, and Spiritual Growth*, Semarang: Untag Press, 2024, ch. XII, pp. 180–195.
- [4] M. Bansal, A. Goyal, and A. Choudhary, “Stock Market Prediction with High Accuracy using Machine Learning Techniques,” in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 247–265. doi: 10.1016/j.procs.2022.12.028.
- [5] M. Rifaai, A. Ananda, and R. Kurniawan, “Perbandingan Algoritma Regresi Linier Dengan Neural Network Untuk Memprediksi Harga Saham Bank Jago,” 2024.

- [6] M. Vijh, D. Chandola, V. A. Tikkwal, and A. Kumar, "Stock Closing Price Prediction using Machine Learning Techniques," in *Procedia Computer Science*, Elsevier B.V., 2020, pp. 599–606. doi: 10.1016/j.procs.2020.03.326.
- [7] Khalis Sofi, Aswan Supriyadi Sunge, Sasmitoh Rahmad Riady, and Antika Zahrotul Kamalia, "Perbandingan Algoritma Linear Regression, LSTM dan GRU dalam Memprediksi Harga Saham dengan Model Time Series," *SEMINASTIKA*, vol. 3, no. 1, pp. 39–46, Nov. 2021, doi: 10.47002/seminastika.v3i1.275.
- [8] R. N. Silalahi and Muljono, "Perbandingan Kinerja Metode Linear Regression, LSTM dan GRU Untuk Prediksi Harga Penutupan Saham Coca-Cola," *Komputika: Jurnal Sistem Komputer*, vol. 13, no. 2, pp. 201–211, Oct. 2024.
- [9] V. Puspaning Ramadhan, F. Yulian Pamuji, and A. History, "Jurnal Teknologi dan Manajemen Informatika Analisis Perbandingan Algoritma Forecasting dalam Prediksi Harga Saham LQ45 PT Bank Mandiri Sekuritas (BMRI) Article Info ABSTRACT," vol. 8, pp. 39–45, 2022, [Online]. Available: <http://http://jurnal.unmer.ac.id/index.php/jtmi>
- [10] O. Barus and C. Wijaya, "Implementasi Metode Neural Network Backpropagation dalam Prediksi Indeks Harga Saham Gabungan (IHSG)," *SEMINASTIKA*, vol. 3, no. 1, pp. 79–85, Nov. 2021, doi: 10.47002/seminastika.v3i1.252.
- [11] M. Muzani, M. Martanto, A. R. Dikananda, and A. Rifai, "Algoritma Backpropagation Neural Network dengan Mengoptimasi Particle Swarm Optimization Untuk Memprediksi Saham Bank BCA," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 2, Apr. 2025, doi: 10.23960/jitet.v13i2.6208.
- [12] H. Hartati, A. H. Saputra, and I. Saluza, "Optimisasi Backpropagation Neural Network dalam Memprediksi IHSG," *Jurnal Ilmiah Informatika Global*, vol. 13, no. 1, Apr. 2022, doi: 10.36982/jiig.v13i1.2066.
- [13] H. Adjie, N. Larasati, and F. Matematika dan Ilmu Pengetahuan Alam, "Analisis Prediksi Harga Saham Bank Central Asia Pasca Stock Split Menggunakan Backpropagation Neural Network dengan Algoritma Inisialisasi Nguyen-Widrow," *Aktuaria dan Data Sains*, vol. 1, no. 2, pp. 26–34, 2024, [Online]. Available: <http://jos.unsoed.ac.id/index.php/skewness/>
- [14] M. Al Haris, L. I. Setyaningsih, F. Fauzi, and S. Amri, "Projection of PT Aneka Tambang Tbk Share Risk Value Based on Backpropagation Artificial Neural Network Forecasting Result," *JTAM (Jurnal Teori dan Aplikasi Matematika)*, vol. 8, no. 2, p. 578, Apr. 2024, doi: 10.31764/jtam.v8i2.20267.
- [15] D. Febiyanti, Nonong Amalita, Dony Permana, and Tessy Octavia Mukhti, "Backpropagation Neural Network Application in Predicting The Stock Price of PT Bank Rakyat Indonesia Tbk," *UNP Journal of Statistics and Data Science*, vol. 1, no. 5, pp. 441–448, Nov. 2023, doi: 10.24036/ujsds/vol1-iss5/113.
- [16] S. Kassaymeh, M. Al-Laham, M. A. Al-Betar, M. Alweshah, S. Abdullah, and S. N. Makhadmeh, "Backpropagation Neural Network optimization and software defect estimation modelling using a hybrid Salp Swarm optimizer-based Simulated Annealing Algorithm," *Knowl Based Syst*, vol. 244, p. 108511, May 2022, doi: 10.1016/J.KNOSYS.2022.108511.
- [17] D. Fu, L. Wang, G. Lv, Z. Shen, H. Zhu, and W. D. Zhu, "Advances in dynamic load identification based on data-driven techniques," *Eng Appl Artif Intell*, vol. 126, Nov. 2023, doi: 10.1016/j.engappai.2023.106871.
- [18] M. Dampfhofer, T. Mesquida, A. Valentian, and L. Anghel, "Backpropagation Based Learning Techniques for Deep Spiking Neural Networks A Survey," *IEEE Trans Neural Netw Learn Syst*, vol. 35, no. 9, pp. 11906–11921, Sep. 2024, Accessed: Jun. 03, 2025. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/10097504>
- [19] S. Y. Heng *et al.*, "Artificial neural network model with different backpropagation algorithms and meteorological data for solar radiation prediction," *Sci Rep*, vol. 12, no. 1, Dec. 2022, doi: 10.1038/s41598-022-13532-3.
- [20] M. A. Z. Raja, S. E. Awan, M. Shoaib, and M. Awais, "Backpropagated Intelligent Networks for the Entropy Generation and Joule Heating in Hydromagnetic Nanomaterial Rheology Over Surface with Variable Thickness," *Arab J Sci Eng*, vol. 47, no. 6, pp. 7753–7777, 2022, doi: 10.1007/s13369-022-06667-y.
- [21] Y. Zhang and L. Shen, "Automatic Learning Rate Adaption for Memristive Deep Learning Systems," *IEEE Trans Neural Netw Learn Syst*, vol. 35, no. 8, pp. 10791–10802, Aug. 2024, Accessed: Jun. 03, 2025. [Online]. Available: <https://ieeexplore.ieee.org/document/10049413>
- [22] "Chapter 4 Statistical techniques for data analysis," *Developments in Water Science*, vol. 51, no. C, pp. 207–276, 2003, doi: 10.1016/S0167-5648(03)80058-8.