

Prediksi Pergerakan Mata Uang dengan Convolutional Neural Network pada Trading Forex: Studi Kasus EUR/USD

Author:

Abdillah Baradja

Afiliation:

Universitas Surakarta

Corresponding email

dillahbaraja@gmail.com

Histori Naskah:

Submit: 2024-02-20

Accepted: 2024-02-22

Published: 2024-02-22



This is an Creative Commons
License This work is licensed
under a Creative Commons
Attribution-NonCommercial 4.0
International License

Abstrak:

Prediksi pergerakan pasar di forex trading merupakan tantangan besar karena ketidakstabilan dan sifat non-linear pasar. Kecerdasan Buatan (AI), khususnya pembelajaran mendalam, telah menarik perhatian sebagai alat bantu dalam pengambilan keputusan trading, mengingat keberhasilannya dalam berbagai aplikasi lain. Penelitian ini bertujuan untuk menguji efektivitas jaringan saraf konvolusional (Convolutional Neural Network - CNN) dalam memprediksi pergerakan pasar forex. Penelitian ini menggunakan metode pembelajaran terawasi dengan algoritma propagasi balik untuk melatih CNN. Data yang digunakan diperoleh dari platform MetaTrader, mencakup nilai tukar harian EUR/USD selama dua tahun (2018-2019). CNN dirancang dengan tiga jenis lapisan: konvolusi, sub-sampling, dan terhubung penuh, dengan tujuan untuk mengidentifikasi pola dalam data dan menghasilkan prediksi yang akurat. Hasil eksperimen menunjukkan peningkatan marginal dalam kinerja CNN dibandingkan dengan model neural network lainnya, terutama dalam hal kesalahan prediksi dan ketepatan sasaran. Walaupun demikian, CNN memerlukan waktu dan sumber daya yang lebih banyak untuk pelatihan. CNN menunjukkan potensi dalam meningkatkan akurasi prediksi pergerakan pasar forex dibandingkan dengan model jaringan saraf lainnya, terutama karena kemampuannya dalam preprocessing data dan mengurangi noise. Namun, tantangan terkait waktu dan sumber daya pelatihan perlu ditangani untuk penerapan yang lebih efisien.

Kata kunci: Supervised Learning, Convolutional Neural Network, Back Propagation Algorithm, Forex Trading, EUR/USD

Pendahuluan

Meramalkan pergerakan pasar dalam forex trading adalah tantangan kompleks karena sifat pasar forex yang tidak stabil dan tidak linear. Keberhasilan dalam trading forex sangat dipengaruhi oleh faktor-faktor seperti kondisi politik, ekonomi lokal dan global, dan faktor lainnya (Bekiros, 2010; Wang et al., 2012; Zhang & Yang, 2017). Menimbang semua faktor ini saat membuat keputusan trading menjadi sulit, sehingga muncul minat besar dalam pemanfaatan Kecerdasan Buatan (AI) untuk pengambilan keputusan.

Minat ini didorong oleh keberhasilan pembelajaran mendalam dalam berbagai aplikasi AI, dari pengenalan suara hingga pemrosesan bahasa alami. Dalam konteks kompleksitas deret waktu keuangan, mengintegrasikan pembelajaran mesin untuk prediksi pasar forex trading dianggap sebagai topik penelitian yang menarik (Cavalcante et al., 2016). Dalam artikel ini kami akan menggunakan pembelajaran yang diawasi (*supervised learning*). Pembelajaran terawasi digunakan ketika ada sekumpulan data awal yang cukup dengan jawaban yang benar untuk pertanyaan yang diajukan. Selama proses pembelajaran, data awal


dimasukkan ke dalam jaringan dan output diverifikasi dengan jawaban yang diketahui benar. Setelah itu, bobot disesuaikan untuk mengurangi kesalahan (Gerlein et al., 2016; Jubert de Almeida et al., 2018). Kami menggunakan algoritma propagasi balik (*back propagation algorithm*). Pendekatan ini memungkinkan pelatihan jaringan saraf tiruan yang berkelanjutan dalam waktu nyata.

Metode ini didasarkan pada penggunaan kesalahan (*error*) jaringan saraf keluaran untuk koreksi bobotnya. Algoritma pembelajaran terdiri dari dua tahap. Pertama, berdasarkan data input, jaringan menghitung nilai yang dihasilkan, yang kemudian diverifikasi dengan nilai referensi dan kesalahan dihitung. Selanjutnya, dilakukan lintasan balik, dengan penyebaran kesalahan dari output jaringan ke inputnya, dengan penyesuaian semua faktor pembobot. Ini adalah pendekatan interaktif dan jaringan dilatih selangkah demi selangkah. Setelah belajar menggunakan data historis, jaringan dapat dilatih lebih lanjut dalam mode online.

Convolutional Neural Network (CNN) termasuk bagian dari pembelajaran mesin yang memainkan peran krusial dalam mengidentifikasi pola pada array data (Sezer & Ozbayoglu, 2018). Operasinya melibatkan konvolusi matematika dengan filter sebagai kernel untuk mencari elemen pola dalam sampel asli. Pola ini tidak ditentukan selama perancangan jaringan, melainkan dipilih selama proses pembelajaran.

Layer sub-sampling kemudian digunakan untuk mengurangi dimensi array fitur dan menyaring noise. Data dipadatkan dengan menyimpan nilai maksimum atau rata-rata dalam "jendela" yang ditentukan. Bergantung pada kompleksitas masalah, kelompok layer konvolusi dan sub-sampling dapat digunakan sebelum array fitur dimasukkan ke multilayer perceptron untuk pengambilan keputusan.

Pelatihan CNN dilakukan dengan propagasi balik dalam pembelajaran terawasi. Gradien kesalahan ditransfer dari output ke input, dan pelatihan layer konvolusi melibatkan operasi konvolusi dan invers konvolusi (Shin et al., 2019). Jaringan ini terdiri dari tiga jenis lapisan (konvolusi, sub-sampling, dan terhubung penuh) dengan pewarisan kelas dan virtualisasi fungsi, membentuk suatu kesatuan dalam pengolahan informasi dan pengambilan keputusan.



Gambar 1. Diagram lapisan-lapisan Convolutional Neural Network (CNN)

Studi Literatur

Dalam beberapa dekade terakhir, model pembelajaran mesin, seperti Jaringan Syaraf Tiruan (JST) (Guo et al., 2014) dan Support Vector Machines (SVR) (Das & Padhy, 2012), telah digunakan luas untuk memprediksi deret waktu keuangan dengan tingkat akurasi yang mencengangkan. Model deep learning, sebagai perkembangan lebih lanjut dari model pembelajaran mesin tradisional, kini diterapkan dalam masalah ini karena mampu memodelkan topologi nonlinier yang kompleks. Kelebihan utama deep learning adalah kemampuannya untuk berhasil memodelkan data dunia nyata yang rumit, mengekstraksi fitur kuat yang menggambarkan informasi relevan, dan akibatnya, mencapai kinerja yang lebih baik (Bengio et al., 2013; Hinton & Salakhutdinov, 2006).

Contoh sukses penggunaan deep learning dalam mengembangkan model trading algoritmik dapat dibagi menjadi dua kategori utama, yaitu metode berbasis pembelajaran mendalam dan metode berbasis pembelajaran penguatan. Sebagai contoh, Arevalo dkk. (Arévalo et al., 2016) mengenalkan strategi perdagangan frekuensi tinggi berdasarkan Deep NN yang mencapai prediksi arah 66% dan 81% perdagangan yang berhasil selama periode pengujian. Pendekatan lain, seperti yang digunakan oleh Bao dkk. (Bao et al., 2017), menggabungkan transformasi wavelet dengan tumpukan autoencoder dan lapisan LSTM untuk memprediksi harga saham. Studi perbandingan oleh M dkk. (Hiransha et al., 2018) menunjukkan bahwa Convolutional Neural Network (CNN) mengungguli Recurrent Neural Network (RNN) dan Long-Short Term Memory (LSTM) dalam memprediksi harga saham di sektor IT dan farmasi.

Sementara itu, beberapa peneliti lebih memfokuskan pada penerapan teknik Reinforcement Learning (RL) untuk mengatasi tantangan perdagangan algoritmik. Moody dan Saell [14] memperkenalkan algoritma pembelajaran penguatan berulang untuk mengidentifikasi kebijakan investasi yang menguntungkan tanpa perlu membuat model peramalan. Dempster dan Leemans [15] menggunakan Pembelajaran Penguatan (Reinforcement Learning) Adaptif untuk berdagang di pasar valuta asing. Keunggulan RL melibatkan penggunaan fungsi reward untuk memaksimalkan imbalan di masa depan, berbeda dengan model regresi dan klasifikasi DL yang berfokus pada prediksi probabilitas hasil. Kombinasi metode ini dalam pendekatan Deep Reinforcement Learning menggabungkan keunggulan keduanya, memungkinkan agen mempelajari fitur yang mendalam dari data pelatihan tanpa memerlukan kumpulan data berlabel yang besar, serta memungkinkan penyesuaian fungsi reward (Deng et al., 2017).

Metode Penelitian

Jaringan syaraf konvolusional (CNN) yang dirancang untuk analisis terdiri dari tiga lapisan syaraf yang berbeda: konvolusional, subsampled, dan sepenuhnya terhubung. Setiap lapisan memiliki kelas syaraf yang unik dan berfungsi secara spesifik untuk proses maju dan mundur. Organisasi metode pemrosesan data yang sesuai dengan syaraf yang sedang diproses menjadi kunci untuk mengintegrasikan semua elemen ini ke dalam jaringan yang padu.

Pemahaman terhadap lapisan input diperoleh melalui evaluasi informasi awal pada setiap candlestick dan perkalian dengan kedalaman data historis yang dianalisis. Data indikator tidak memerlukan pra-pemrosesan karena sudah dinormalisasi, namun, untuk data harga candlestick, normalisasi diperlukan. Dengan memasukkan selisih harga Close, High, dan Low dari harga Open candlestick, tiga syaraf dibuat di mana tanda dari syaraf pertama menentukan arah candlestick.

Dalam konteks faktor waktu yang mempengaruhi volatilitas mata uang, penambahan bulan, jam, dan hari pembentukan candlestick ke dalam jaringan syaraf memberikan keunggulan analisis yang lebih mendalam. Informasi tersebut diurai secara rinci untuk memungkinkan jaringan syaraf menggeneralisasi dan

mengidentifikasi ketergantungan. Informasi volume, baik itu riil atau tik juga diperhitungkan untuk memperkaya analisis. Sebagai hasilnya, diperlukan 12 syaraf untuk menggambarkan setiap candlestick, dan ukuran lapisan input jaringan syaraf ditentukan oleh hasil perkalian jumlah ini dengan kedalaman sejarah yang dianalisis.

Langkah berikutnya adalah mempersiapkan lapisan tersembunyi (*hidden layer*) dari jaringan syaraf. Menentukan struktur jaringan merupakan tugas yang menantang. Dengan menetapkan jumlah syaraf dalam lapisan tersembunyi pertama, dan menerapkan aturan Pareto untuk mengurangi jumlah syaraf di lapisan berikutnya, serta memberlakukan batas minimum, kompleksitas jaringan dapat dipertahankan tanpa mengorbankan konvergensi.

Terakhir, jumlah syaraf dalam lapisan output tergantung pada tujuan. Dua variasi jaringan syaraf diajukan: yang pertama dengan satu syaraf di lapisan output, menghasilkan sinyal beli, jual, atau tidak ada sinyal; dan yang kedua dengan tiga syaraf, memproduksi probabilitas munculnya fractal. Dengan memanfaatkan fungsi aktivasi tangen hiperbolik, jaringan syaraf ini dirancang untuk menyajikan hasil yang berguna sesuai dengan tujuan analisis.

Data yang digunakan dalam penelitian kami diunduh dari platform MetaTrader selama sesi pembukaan pasar forex (senin-jum'at). Dataset ini memberikan informasi seputar nilai tukar harian dari pasangan mata uang EUR/USD, yang merupakan fokus utama analisis kami. Rentang waktu dataset mencakup periode yang signifikan, yaitu selama 2 tahun, dimulai dari tanggal 1 Januari 2018 hingga 31 Desember 2019. Pemilihan rentang waktu ini dirancang untuk memberikan gambaran yang komprehensif dan mendalam mengenai fluktuasi nilai tukar dalam jangka waktu yang cukup panjang.

Hasil

Dalam rangka menguji kinerja Convolutional Neural Network (CNN), penelitian ini bertujuan untuk melatih jaringan syaraf untuk memprediksi kemunculan fractal pada candlestick saat ini. Metode yang digunakan melibatkan penyediaan informasi tentang pembentukan candlestick terakhir dan data dari 4 osilator untuk periode yang sama ke dalam jaringan syaraf.

Pada lapisan konvolusi CNN, dibentuk 4 filter yang dirancang untuk mencari pola dalam data total pembentukan candlestick dan pembacaan osilator pada candlestick yang sedang dianalisis. Pengaturan filter, termasuk jendela dan langkah, disesuaikan dengan jumlah data per deskripsi candlestick. Pendekatan ini memungkinkan pengayaan data awal dengan informasi baru tentang candlestick tanpa pengurangan kinerja yang signifikan.

Selanjutnya, lapisan konvolusi mencari elemen pola di seluruh sampel asli. Pada setiap iterasi, template digeser di sepanjang larik data awal dengan langkah tertentu, yang ukurannya bisa dari "1" hingga ukuran pola. Jika ukuran langkah offset kurang dari ukuran pola, konvolusi seperti itu disebut tumpang tindih.

Operasi konvolusi menghasilkan larik fitur yang menunjukkan "kemiripan" data asli dengan pola yang diperlukan pada setiap iterasi. Fungsi aktivasi digunakan untuk menormalkan data. Ukuran array yang dihasilkan akan lebih kecil dari array data asli. Jumlah array tersebut sama dengan jumlah filter.

$$\frac{\text{Count}_{\text{input data}} - \text{Count}_{\text{filter}}}{\text{Step}} + 1 = \text{Count}_{\text{conv}} \quad (1)$$

Poin penting yang dilakukan adalah bahwa pola-pola tersebut tidak ditentukan saat mendesain jaringan saraf, tetapi dipilih dalam proses pembelajaran.




Gambar 2. Terminal MetaTrader 5 dengan fractal indicators


Eksperimen dilaksanakan pada pasangan mata uang EURUSD dengan kerangka waktu H1. Tiga Expert Advisor diterapkan, satu menggunakan *regression neural network* dengan 1 neuron pada lapisan output, *classification neural network* dengan 3 neuron pada lapisan output dan *convolutional neural network* dari simbol yang sama di terminal yang sama. Parameter lapisan terhubung penuh sesuai dengan parameter jaringan terhubung penuh.

Pembahasan

Hasil pengujian menunjukkan peningkatan kinerja yang marginal pada CNN, meskipun ditambahkan dua lapisan. Waktu pelatihan rata-rata untuk satu epoch (*iterasi* pelatihan) CNN adalah 1 jam 20 menit, sedangkan untuk regression neural network adalah 2 jam 10 menit dan untuk classification neural network adalah 2 jam 15 menit. CNN menunjukkan hasil sedikit lebih baik dalam hal kesalahan prediksi dan mencapai target. Setelah 30 epoch pelatihan, perbedaan dalam statistik sedikit meningkat - model jaringan saraf regresi berkinerja lebih baik.



Gambar 3. Grafik Root mean square error



Gambar 4. Grafik total prosentase keuntungan prediksi dalam 2 tahun

Pelatihan jaringan syaraf (*neural network*) dilakukan pada pasangan mata uang EURUSD dengan kerangka waktu H1, menggunakan data 20 candlestick selama 2 tahun terakhir (2018 – 2019). Tiga *Expert Advisor* dengan arsitektur jaringan yang berbeda diaktifkan pada terminal yang sama untuk membandingkan hasil. Epoch pertama pelatihan pada 6197 batang lilin (*candlestick*) memakan waktu 2 jam 10 menit. Pengujian model menggunakan Root Mean Square Error (RMSE) untuk mengevaluasi nilai akurasi model prediksi.

Kesimpulan

Dari hasil pengujian menunjukkan bahwa varian organisasi jaringan syaraf menghasilkan hasil yang serupa dalam hal waktu pelatihan dan akurasi prediksi, akan tetapi untuk CNN menunjukkan hasil yang sedikit lebih baik dalam hal kesalahan prediksi dan "ketepatan sasaran". Meski demikian, hasil menunjukkan bahwa jaringan syaraf membutuhkan waktu dan sumber daya tambahan untuk pelatihan.

Tabel 1. Hasil akhir pengujian tiga model neural network

Test Result	Regression Neural Network	Classification Neural Network	Convolutional Neural Network
Root mean square error	0.63	0.56	0.42
Hit percentage	11.35%	7.9%	25.45%

Pada artikel ini, kami telah menguji kemungkinan menggunakan jaringan saraf convolutional di pasar keuangan. Pengujian telah menunjukkan bahwa dengan menggunakannya, kita dapat meningkatkan hasil dari jaringan saraf yang terhubung sepenuhnya. Hal ini dapat dihubungkan dengan preprocessing data yang kita masukkan ke dalam perceptron yang terhubung penuh. Data asli disaring di lapisan convolutional dan subsampel untuk menghilangkan noise, yang meningkatkan kualitas data sumber dan kualitas jaringan saraf. Selain itu, pengurangan dimensi membantu mengurangi jumlah koneksi perceptron dengan data asli, yang memberikan peningkatan kinerja

Referensi

- Arévalo, A., Niño, J., Hernández, G., & Sandoval, J. (2016). High-frequency trading strategy based on deep neural networks. *International Conference on Intelligent Computing*, 424–436.
- Bao, W., Yue, J., & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PloS One*, 12(7), e0180944.
- Bekiros, S. D. (2010). Fuzzy adaptive decision-making for boundedly rational traders in speculative stock markets. *European Journal of Operational Research*, 202(1), 285–293.
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798–1828.
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. F., Nobrega, J. P., & Oliveira, A. L. I. (2016). Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, 55, 194–211.
- Das, S. P., & Padhy, S. (2012). Support vector machines for prediction of futures prices in Indian stock market. *International Journal of Computer Applications*, 41(3).
- Deng, Y., Bao, F., Kong, Y., Ren, Z., & Dai, Q. (2017). Deep Direct Reinforcement Learning for Financial Signal Representation and Trading. *IEEE Transactions on Neural Networks and Learning Systems*, 28(3), 653–664. <https://doi.org/10.1109/TNNLS.2016.2522401>
- Gerlein, E. A., McGinnity, M., Belatreche, A., & ... (2016). Evaluating machine learning classification for financial trading: An empirical approach. *Expert Systems with ...*. <https://www.sciencedirect.com/science/article/pii/S0957417416000282>
- Guo, Z., Wang, H., Liu, Q., & Yang, J. (2014). A feature fusion based forecasting model for financial time

series. *PloS One*, 9(6), e101113.

Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504–507.

Hiransha, M., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2018). NSE stock market prediction using deep-learning models. *Procedia Computer Science*, 132, 1351–1362.

Jubert de Almeida, B., Ferreira Neves, R., & Horta, N. (2018). Combining Support Vector Machine with Genetic Algorithms to optimize investments in Forex markets with high leverage. *Applied Soft Computing*, 64, 596–613. <https://doi.org/10.1016/j.asoc.2017.12.047>

Sezer, O. B., & Ozbayoglu, A. M. (2018). Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach. *Applied Soft Computing*. <https://www.sciencedirect.com/science/article/pii/S1568494618302151>

Shin, H.-G., Ra, I., & Choi, Y.-H. (2019). *A Deep Multimodal Reinforcement Learning System Combined with CNN and LSTM for Stock Trading*. 7–11. <https://doi.org/10.1109/ICTC46691.2019.8939991>

Wang, B., Huang, H., & Wang, X. (2012). A novel text mining approach to financial time series forecasting. *Neurocomputing*, 83, 136–145.

Zhang, Y., & Yang, X. (2017). Online portfolio selection strategy based on combining experts' advice. *Computational Economics*, 50, 141–159.