

Conditional Restricted Boltzmann Machine (CRBM) Untuk Memprediksi Harga Saham

Patma Oktaviana¹, Jondri S.Si.,M.si², Rian Febrian Umbara, M.Si³

^{1,2,3} Prodi Ilmu Komputasi, Fakultas Informatika, Universitas Telkom, Bandung

¹vianocta@students.telkomuniversity.ac.id, ²jondri@telkomuniversity.ac.id, ³rianum@telkomuniversity.ac.id

Abstrak

Meramalkan pergerakan harga saham dengan benar dapat memberikan keuntungan yang ekonomis secara nyata di masa depan. Dalam Tugas Akhir metode yang digunakan untuk melakukan prediksi ialah metode CRBM, metode ini dikenal cukup optimal dalam memprediksi data yang berdasarkan dari periode masa lalu.

Metode *Conditional Restricted Boltzmann Machine* (CRBM) adalah model probabilistik yang baru-baru ini diterapkan untuk memecahkan berbagai masalah, termasuk penyaringan kolaboratif, klasifikasi, dan pemodelan *motion capture data*. CRBM juga merupakan model dimensi tinggi *time series* dan memiliki derajat yang tinggi dalam paralelisasi. CRBM juga sering digunakan dalam berbagai hal yang berkaitan dengan menentukan akurasi peramalan, misalnya dari pelacakan gerak. Oleh karena itu, dalam Tugas Akhir ini penulis tertarik mengangkat topik ini dengan metode CRBM yang mempunyai kemampuan generik yang sangat baik pada penelitian *motion capture*.

Untuk melakukan penelitian ini, petama-pertama yang harus dilakukan ialah analisis eksplorasi, dimana petingnya menentukan beberapa skenario pengujian dari beberapa dataset periode masa lalu. Kemudian melakukan analisis komparatif, dimana pengujian awal dibandingkan dengan beberapa skenario perbandingan lainnya untuk menentukan apakah masih ada hasil yang lebih baik lainnya dari skenario yang awalnya diusulkan.

Penelitian menggunakan data historis yang berasal dari Bursa Efek Indonesia dan termasuk salah satu bagian dari LQ45. Metode dilatih pada data mingguan, untuk memprediksi jangka pendek untuk satu minggu kedepan. Berdasarkan penelitian yang telah dilakukan dapat diketahui bahwa akurasi prediksi terbaik didapatkan pada periode 2014-2015, dengan MAPE 17,449%.

Kata kunci : *Conditional Restricted Boltzmann Machine, Restricted Boltzmann Machine, CRBM, RBM, Prediksi Pasar Saham.*

Abstract

Predicting the right stock price movements can provide real economic benefits in the future. In the Undergraduate Thesis the method used to make predictions is the CRBM method, this method is known to be optimal in predicting data based on the previous period.

Conditional Methods Restricted Boltzmann Machine (CRBM) is a new probabilistic model applied to solve problems, including collaborative filtering, classification, and motion data. CRBM is also a high time series dimension model and has a high degree of parallelization. CRBM is also often used in various matters relating to the determination of the accuracy of forecasting, for example from motion tracking. Therefore, in this Undergraduate Thesis the author is interested to study this topic with CRBM method which has excellent generic capability in motion capture research.

To do this research, the first thing to do is an explorative analysis, where it defines some test scenarios from some previous period datasets. Then do a comparative analysis, where the initial test is compared with some other comparability scenarios to see if there are still other results that are better than the original scenario.

This study uses historical data derived from Indonesia Stock Exchange and includes part of LQ45. A methode trained in weekly data, to make short term predictions for one week ahead. Base on the results of research that has been done can be seen that the best prediction accuracy obtained in the period 2014-2015, with MAPE 17,449%

1. Pendahuluan

Saham adalah tanda penyertaan atau kepemilikan seseorang atau badan dalam suatu perusahaan atau perusahaan terbatas yang sangat banyak dipilih sebagai sumber investasi karena mampu memberikan keuntungan yang sangat menarik. Saham juga merupakan salah satu pilihan perusahaan untuk memperoleh pendanaan/pemodalanan perusahaan. Pergerakan pasar saham yang dinamis juga mampu memberikan kerugian sehingga pengambilan keputusan dalam memperjual belikan saham merupakan salah satu faktor yang sangat dipertimbangkan dan hati-hati.

Karena harga saham sulit diprediksi banyak para investor ataupun para pengamat mengembangkan model dan teknik dalam upaya menilai tren pasar untuk memperoleh keuntungan. Model-model dalam menentukan harga saham telah banyak digunakan antara lain: *Neural Networks*[1], *Model ARIMA* [2], *ARIMA and Artificial Neural Network Models* [3] *Data Mining* [4][5], *Recurrent Neural Networks*[6], *Hidden Markov Models* [7], *Teknik Machine Learning* [8], *Time Series Analysis* [9], *Deep Learning Architecture* [10] dan *Restricted Boltzmann Machine* (RBM) [15]

Pada Tugas Akhir ini digunakan metode *Conditional Restricted Boltzmann Machine* (CRBM) untuk memprediksi harga saham.

Latar Belakang

Menurut *Efficient Market Hypothesis* (EMH) [21], harga pasar saham mengikuti pola *random walk*, yang berarti bahwa saham memiliki probabilitas yang sama pada saat naik begitu pula pada saat turun, sehingga prediksi tidak bisa memiliki akurasi lebih dari 50%[22]. *EMH* menyatakan bahwa harga saham sebagian besar didorong oleh “berita” daripada harga yang diperoleh dari data saat ini dan masa lalu. Namun, ada pula yang menyatakan bahwa harga pasar saham tidak mengikuti *random walk* dan dapat diprediksi[23].

Pasar saham sulit untuk diprediksi. Didorong oleh penawaran dan permintaan, perubahan ekonomi makro seperti inflasi atau ketidakstabilan politik dapat mempengaruhi seluruh pasar, sementara kegiatan seperti pengumuman keuangan perusahaan atau rilisnya produk berdampak hanya pada saham individu. Para *trader* juga mencari sinyal dalam pergerakan harga yang memberikan indikasi harga dimasa depan. Karena beberapa perdagangan didasarkan pada pergerakan harga dengan sendirinya juga dapat memicu aktivitas jual beli, sehingga menyebabkan penyesuaian harga lebih lanjut. Investor dan *trader* idealnya harus mempertimbangkan semua ini ketika mengevaluasi sebuah saham. Bagaimana pun, pelaku pasar sering dibagi menjadi dua kelompok: *Investor* yang membuat keputusan berdasarkan berita, fakta dan angka yang terkait dengan perusahaan dikenal sebagai analisis fundamental, *trader* yang membuat keputusan berdasarkan histori harga saham dan *rumors* yang dikenal sebagai analisis teknikal [9].

Dengan munculnya komputer digital, prediksi pasar saham telah pindah keranah teknologi. Bentuk yang paling umum adalah menggunakan metode dari ANN. Yang sering digunakan untuk prediksi pasar saham pada ANN adalah *feed forward network* yang memanfaatkan *backward propagation* dari kesalahan algoritma untuk memperbarui bobot jaringan. Jaringan ini biasanya disebut sebagai jaringan *Backpropagation*. Bentuk lain dari ANN yang lebih tepat untuk prediksi saham adalah *Recurrent Neural Network* (RNN) atau *Time Delay Neural Network* (TDNN)[15].

Topik dan Batasannya

Topik yang diangkat dalam Tugas Akhir ini adalah Prediksi Harga Saham menggunakan data saham PT. Adaro Energy Tbk (Pertambangan Batu Bara) yang diambil dari <http://yahoo.finance.com>. Data yang dipilih berdasarkan observasi selama lima tahun dari tanggal 12 Agustus 2012 sampai dengan 6 Agustus 2017 yang merupakan data historis mingguan. Jumlah data historis mingguan yang tersedia pada rentang waktu tersebut sebanyak 261 data. Data yang didapatkan terdiri dari *Date*, *Open*, *High*, *Low*, *Close*, *Adj Close* dan *Volume*. Namun, yang digunakan pada Tugas Akhir ini hanya data *Close* untuk pengolahan data.

Adapun batasan masalah pada Tugas Akhir ini berdasarkan latar belakang yang sudah dibahas di atas, adalah: 1) Bagaimana penggunaan *Conditional Restricted Boltzmann Machine* (CRBM) untuk prediksi Harga Saham? 2) Bagaimana menganalisis keakuratan akurasi menggunakan MSE dan MAPE setelah menemukan hasil prediksi harga saham?

Dari beberapa batasan masalah tersebut, jumlah data yang digunakan pada tugas akhir ini relatif lebih sedikit dari penelitian sejenis dengan metode yang sama, selain itu keterbatasan kemampuan kinerja komputer yang tersedia.

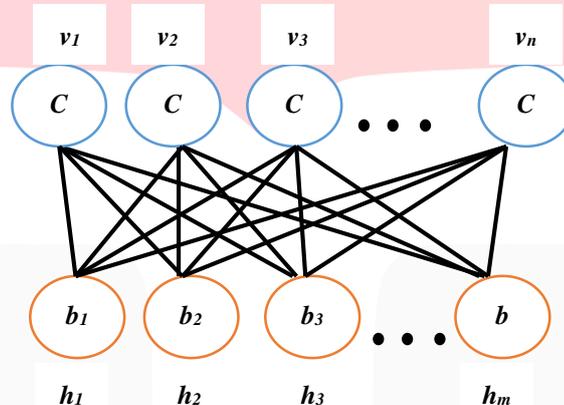
Tujuan

Tujuan yang ingin dicapai dalam penyusunan tugas akhir ini yaitu mencoba mengimplementasikan metode *Conditional Restricted Boltzmann Machine* (CRBM) untuk memprediksi harga saham dari beberapa skenario pengujian yang sudah disediakan, dan setelah mendapatkan hasil prediksi yang baik akan dilakukan analisis untuk mengetahui akurasi menggunakan MSE dan MAPE dari beberapa skenario pengujian yang telah dilakukan.

2. Studi Terkait

2.1 Restricted Boltzmann Machine (RBM)

Restricted Boltzmann Machine (RBM) adalah model probablistik generativ antara variabel input *visible* (terlihat), v dan variabel *hidden* (tersembunyi /tidak terlihat), h . RBM (juga dilambangkan sebagai Harmonium) dapat didefinisikan sebagai graf bipartit simetris. Bipartit berarti memiliki dua bagian, atau lapisan dan grafik yang merupakan istilah untuk *web node*. Yaitu terdiri dari m variabel *visible* (terlihat) $V = (V_1, \dots, V_m)$ berfungsi untuk mewakili data yang dapat diobservasi dan n variabel *hidden* (tersembunyi) $H=(H_1, \dots, H_n)$ berfungsi untuk menangkap permasalahan antara variable yang sedang diamati. Pada kasus ini, kita menggunakan variabel $(v, h) \in \{0,1\}^{m+n}$ dengan gabungan distribusi probabilitas.



Gambar 2-1 Grafik tidak berarah dari RBM dengan n sebagai variabel Hidden dan

Grafik dari RBM (gambar 2-1) hanya memiliki koneksi antara *layer* (lapisan) variabel *hidden* (tersembunyi) dan variabel *visible* (terlihat), tetapi tidak diantara dua variabel dari lapisan (*layer*) yang sama. Dalam probabilitas, hal ini berarti bahwa variabel *hidden* (tersembunyi) bersyarat independen yang memberikan *state* atau satu sama lain, dan begitu pula sebaliknya. Dengan menggunakan pernyataan ini, kita dapat menuliskannya sebagai [11] ;

$$p(h | v) = \sigma \left(b_j + \sum_i W_{ij} v_i \right) \quad (1)$$

dan

$$p(v | h) = \sigma \left(c_i + \sum_j W_{ij} h_j \right) \quad (2)$$

Dimana $\sigma(\cdot)$ adalah fungsi aktivasi. Fungsi logistik, $\sigma(v) = \frac{1}{1 + e^{-v}}$ adalah pilihan umum untuk fungsi aktivasi. Parameter W , b dan v dilatih menggunakan *contrastive divergence*.

2.2 Contrastive Divergence

Algoritma *Contrastive Divergence* (CD) yang diperkenalkan di [17], adalah algoritma pembelajaran untuk *Product of Experts* (PoE). PoE bekerja dengan menormalisasi produk dari beberapa model ahli. Dengan mempertimbangkan setiap variabel *hidden* dalam RBM sebagai ahli, RBM dapat dinyatakan sebagai kasus khusus PoE. Oleh karena itu, pelatihan CD menarik juga dalam konteks RBM. Untuk informasi lebih lanjut mengenai model PoE dan hubungannya dengan RBM [17].

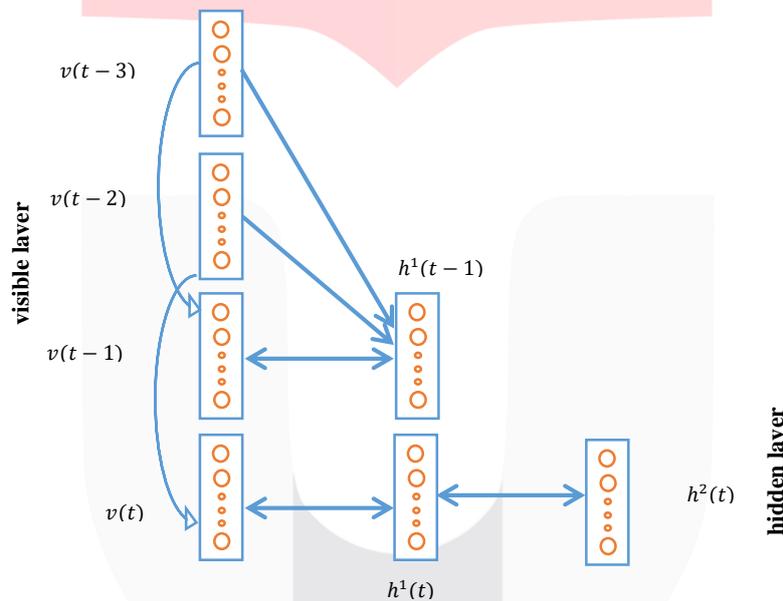
Sebagai model *unsupervised*, RBM tidak dapat menghitung dan menyebarkan kesalahan yang serupa dengan FFNN. Namun, seperti telah dibahas, kita dapat melakukan pengambilan sampel Gibbs alternatif untuk menciptakan rekonstruksi sampel masukan asli. CD memanfaatkan properti ini, dan menghitung kesalahan berdasarkan perbedaan antara keadaan asli dan yang direkonstruksi. Bobot diperbarui mengikuti persamaan (3):

$$\Delta w_{ij} = \epsilon (\langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{recon}}) \tag{3}$$

Dimana ϵ adalah tingkat pembelajaran dan kurung siku menunjukkan harapan di bawah distribusi tertentu, yaitu data atau rekonstruksi. Dengan kata lain, $\langle v_i h_j \rangle_{\text{data}}$ adalah produk antara unit asli *visible* j dan unit *hidden* yang diambil dari vector input. $\langle v_i h_j \rangle_{\text{recon}}$ dihitung secara ekuivalen, kecuali menggunakan rekonstruksi. Dengan kata lain $\langle \cdot \rangle$ adalah nilai rata-rata dari semua sample pelatihan. Beberapa RBM dapat ditumpuk untuk menghasilkan *deep belief network* (DBN). Pada *deep network*, pengaktifan variabel hidden pada lapisan pertama adalah input ke lapisan ke dua. CD_k adalah ekstensi ke CD, dimana pengambilan sampel *Gibbs* dilakukan pada waktu bergantian. Meskipun meningkatkan beban komputasi, Pada jurnal [18] menyatakan bahwa CD_k biasanya menghasilkan model yang lebih baik [1].

2.3 Conditional Restricted Boltzmann Machine (CRBM)

CRBM awalnya digunakan pada *time series* untuk menangkap gerakan data, *Conditional Restricted Boltzmann Machine* (CRBM) seperti yang dijelaskan dalam jurnal G.Taylor [13] menawarkan cara pemodelan hubungan temporal antara beberapa variabel. *Motion capture data* melacak beberapa variabel, misalnya mewakili sudut sendi yang berbeda dalam tubuh.



Gambar2-2 Sebuah Conditional RBM 2-layer untuk data time-series. Model rangka untuk pertama dan lapisan kedua adalah 3 dan 2, berurutan.

CRBM adalah ekstensi untuk RBM, dimana beberapa lapisan visible mewakili *variabel* pada langkah waktu yang berbeda. Gambar.2-2 menunjukkan contoh dimana dua langkah waktu dianggap: Keadaan saat terjadi, dan dua langkah sebelumnya. Model ini memiliki dua urutan, karena memerlukan setidaknya dua langkah waktu untuk dicoba.

Lapisan *visible* tambahan memegang *state* untuk langkah waktu sebelumnya menggunakan arah koneksi, sehingga bertindak lebih seperti bias dinamis daripada lapisan *visible* biasa. Dengan kata lain, lapisan *visible* dan *hidden* keduanya disimpulkan tergantung pada *variabel* sebelumnya [1].

CRBM (Gambar 2-2) adalah model generatif *non-linear* untuk data *time series* yang menggunakan model terarah dengan biner variabel laten, \mathbf{h} , terhubung ke koleksi variabel *visible*, \mathbf{v} . Variabel *visible* bisa menggunakan distribusi dari keluarga eksponensial [14], namun untuk data *motion capture*, kita menggunakan unit Gaussian bernilai riil (Freund & Haussler, 1992). Pada setiap langkah waktu t , \mathbf{v} dan \mathbf{h} menerima langsung koneksi dari variabel *visible* pada N *timesteps* terakhir.

Vektor Bias dalam CRBM tergantung pada variabel yang terlihat sebelumnya dan didefinisikan sebagai,

$$a_{i,t}^* = a_i + \sum_{k=1}^n A_{ki} v(t - i) \tag{4}$$

dan

$$b_{j,t}^* = b_j + \sum_{k=1}^n B_{kj}v(t-k) \quad (5)$$

persamaan di atas menyatakan *net input* sebelumnya dari variabel *visible* dan *hidden*, yang berurutan. Maksudnya ialah di mana A_i adalah koneksi *auto-regresif* antara variabel *visible* pada waktu $t-1$ dan aliran variabel *visible*, B_i adalah matrik bobot yang menghubungkan lapisan *visible* pada waktu $t-1$ ke aliran variabel *hidden*. Urutan Model didefinisikan oleh n konstan. Seperti yang biasa dilakukan, kita tetapkan $\sigma_i = 1$. Probabilitas untuk naik atau turun pada lapisan adalah;

$$P(h_j|v) = \sigma \left(a_j + \sum_i W_{ji}v_i + \sum_k \sum_j A_{ijk}v(t-k) \right) \quad (6)$$

$$P(v_i|h) = \sigma \left(b_j + \sum_i W_{ji}h_i + \sum_k \sum_i B_{ijk}v(t-k) \right) \quad (7)$$

Parameter $\{W, a, b, A, B\}$, dapat dilatih menggunakan *Contrastive Divergence*. Sama seperti RBM, CRBM dapat digunakan sebagai modul untuk membuat *deep Networks*, dan dapat menambahkan lapisan seperti *Deep Belief Network* [15].

2.4 Mean Squared Error

Mean Squared Error (MSE) adalah indikator yang banyak digunakan untuk mengukur kesalahan dalam *machine learning*, dan mengekspresikan jarak rata-rata antara perkiraan dan nilai ideal. MSE menyediakan pengetahuan, Bila akurat merupakan hal yang sangat penting. Hal ini dihitung dengan rata-rata kesalahan prediksi kuadrat, yang berarti MSE rendah diterjemahkan keprediksi mendekati nilai ideal.

$$MSE = \frac{1}{n} \sum (\hat{y}_t - y_t)^2 \quad (8)$$

dimana n adalah jumlah prediksi dan \hat{y}_t dan y_t adalah nilai prediksi dan nilai ideal masing-masing[1].

2.5 Mean Absolute Percentage Error

MAPE (*Mean Absolute Persen Error*) mengukur ukuran kesalahan dalam persentase. Hal ini dihitung sebagai rata-rata kesalahan persentase *unsigned*, seperti yang ditunjukkan pada contoh di bawah ini:

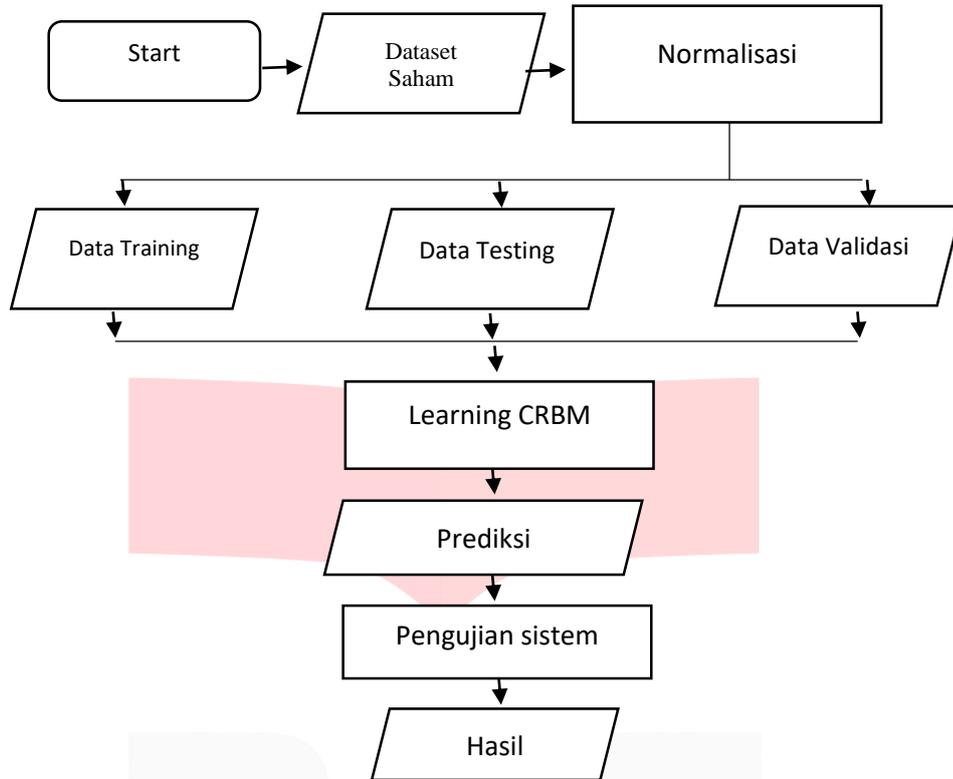
$$MAPE = \frac{100}{N} \times \sum_{i=1}^N \left| \frac{x_i - \hat{x}_i}{x_i} \right| \quad (9)$$

Dimana $\{x_i\}$ adalah rangkaian waktu pengamatan aktual pada periode i , $\{\hat{x}_i\}$ adalah nilai peramalan pada deret waktu i dan N adalah jumlah data[20].

3 Sistem yang Dibangun

1. Melakukan input data *Close* harga saham mingguan PT.Adro Energy Tbk, yang berupa data vektor.
2. Melakukan normalisasi data
 3. Membagikan data ke dalam beberapa skenario;
 - Skenario 1 : Periode 1 Tahun (2012-2013)
 - Skenario 2 : Periode 2 Tahun (2012-2014)
 - Skenario 3 : Periode 3 Tahun (2012-2015)
 - Skenario 4 : Periode 4 Tahun (2012-2016)
 - Skenario 5 : Periode 5 Tahun (2012-2017)
4. Membagi data yang sudah dinormalisasi tersebut menjadi 3 data yaitu data training, validasi dan data testing.
5. Membuat model untuk melakukan pengujian

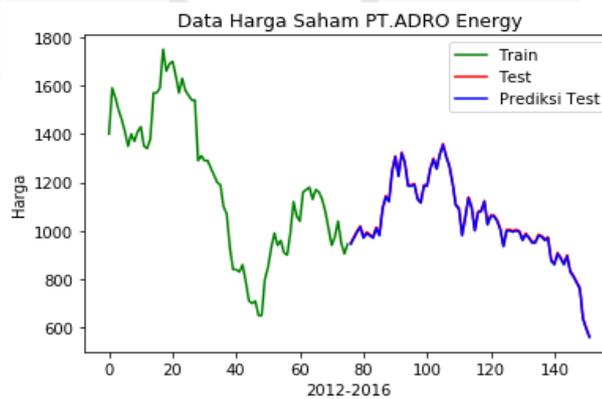
6. Melakukan Training untuk mendapatkan hasil prediksi data uji dengan MSE dan MAPE untuk menganalisa hasil yang diperoleh dari langkah 1 sampai 5



Gambar 3.1 Alur Sistem Kerja

4 Evaluasi

4.1 Hasil Pengujian



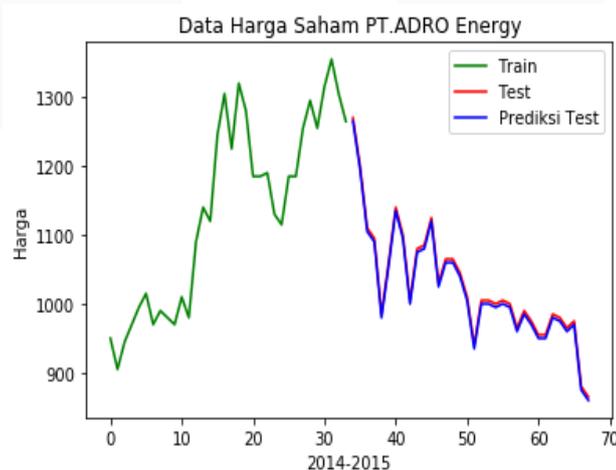
Gambar 4.1 Plot Prediksi 1 minggu ke-depan

Tabel 4.1 Hasil MSE dan MAPE Per-Periode

Tahun	Jumlah Training	MSE	MAPE
2012-2013	24	291908,3	25,468
2012-2014	41	257898,2	31,921
2012-2015	59	175922,9	30,536
2012-2016	76	89055,59	21,651
2012-2017	87	119338,8	26,838

Dari hasil data historis mingguan pada harga *Close* saham PT. ADRO Energy didapatkan hasil prediksi data uji MSE dan MAPE. Pada hasil simulasi ditunjukkan hasil percobaan yang dilakukan pada 5 (lima) skenario yang telah dilakukan berdasarkan pada langkah-langkah pengujian sistem. Pengujian sistem berdasarkan skenario yang telah ditetapkan dimana dilakukan percobaan menggunakan periode 1 tahun (2012-2013), periode 2 tahun (2012-2014), Periode 3 tahun (2012-2015), periode 4 tahun (2012-2016) dan periode 5 tahun (2012-2017). Setelah sampel data dikumpulkan, tugas selanjutnya adalah membagikan data tersebut menjadi tiga set, yaitu untuk pelatihan, validasi dan pengujian. Set pelatihan berisi sampel yang menjadi sasaran *learning algorithm* model. Seperti contohnya pada Gambar 4.1 untuk mengetahui prediksi untuk data priode 4 tahun untuk satu minggu kedepan dan seterusnya digunakan metode CRBM pada Python.

Pada Tabel 4.1 didapatkan hasil data uji dengan MAPE terbaik yaitu pada peride 4 tahun atau pada tahun 2012-2016 dengan nilai 21.651%. Dari hasil terbaik yang didapatkan, penulis mencoba menguji dengan data pembanding. Data Pembanding diambil setiap empat tahun selama periode lima tahun dari tahun 2012 sampai dengan 2017 untuk melihat apakah disetiap pola periode yang sama selalu menghasilkan MAPE yang lebih baik dari periode lainnya. Karena pola periode empat tahun dalam masa 2012-2017 mempunyai lingkup yang sedikit maka penulis mencoba dengan membandingkan dengan periode satu tahun. Hasilnya didapatkan pada pola periode satu tahun, MAPE terbaik ada pada tahun 2014-2015 dengan nilai MAPE 17,449 % seperti dapat dilihat pada Gambar 4.2 dan Tabel 4.2. Dan ini menyatakan keakuratan prediksi yang baik tidak ada aturan yang pasti yang mempengaruhi pola periode pada data historis yang ada.



Gambar 4.2 Plot Prediksi Minggu ke-35 dan seterusnya

Tabel 4.2 Hasil MSE dan MAPE
Per-Periode 1 tahun

Tahun	Jumlah Training	MSE	MAPE
2012-2013	24	291908,3	25,468
2013-2014	34	96668,38	22,035
2014-2015	34	54702,94	17,449
2015-2016	34	96853,24	33,441
2016-2017	28	540823,2	96,427

4.2 Analisis Hasil Pengujian

Setelah prediksi dilakukan untuk setiap langkah waktu dalam dataset pelatihan, nilai tersebut dibandingkan dengan nilai yang diharapkan dan skor *Mean Squared Error* (MSE) dengan *Mean Absolute Percentage Error* (MAPE). Tabel 4.1 dan 4.2 menunjukkan MSE dan MAPE dalam metode ini sebagai metode terbaik dan dapat digunakan untuk prediksi. Ini juga membuktikan bahwa hasil tersebut cukup baik, sesuai pada plotnya pada Gambar. 4-1 dan 4-2 yang hampir berimpit pada hasil vektor asli dengan hasil prediksi.

5 Kesimpulan

Dari hasil pengujian yang telah dilakukan dapat diambil beberapa kesimpulan sebagai berikut:

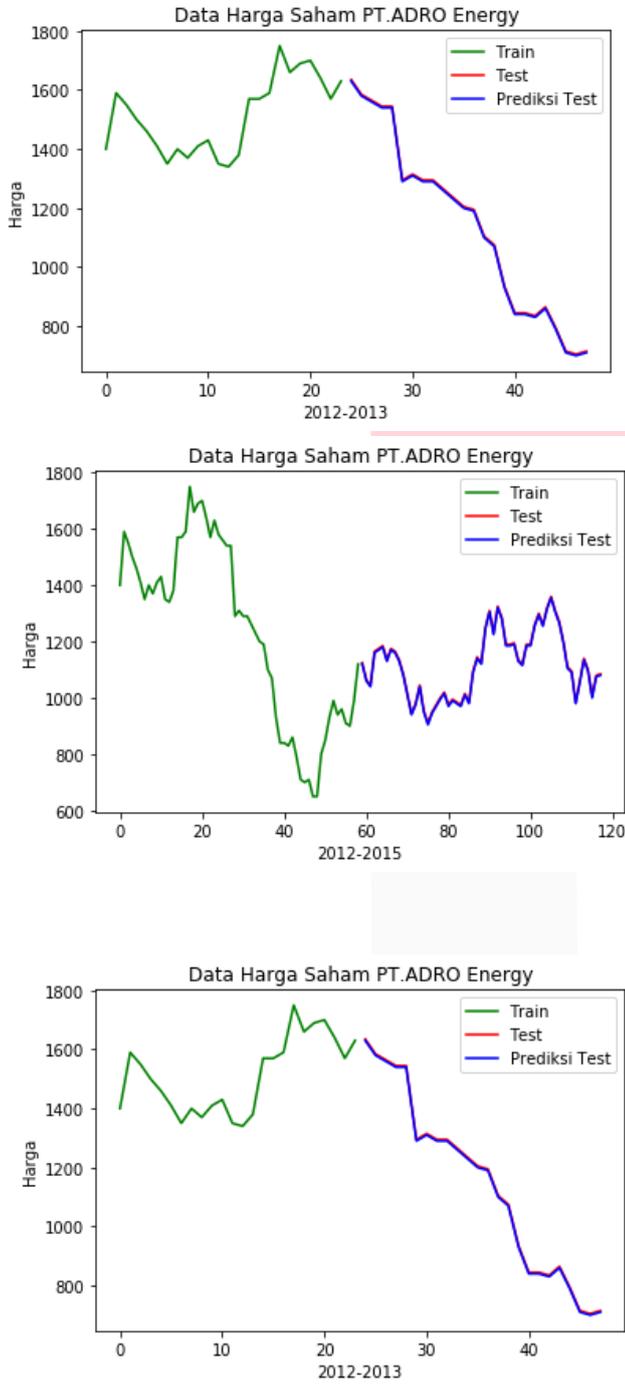
1. Untuk menghasilkan hasil keakuratan prediksi yang baik tidak ada aturan yang pasti yang mempengaruhi pola periode data historis yang ada.
2. Akurasi prediksi yang dihasilkan pada akhirnya ditemukan pada dataset pembandingan pada periode dua tahun 2014-2015 dengan MAPE 17,449%.

Daftar Pustaka

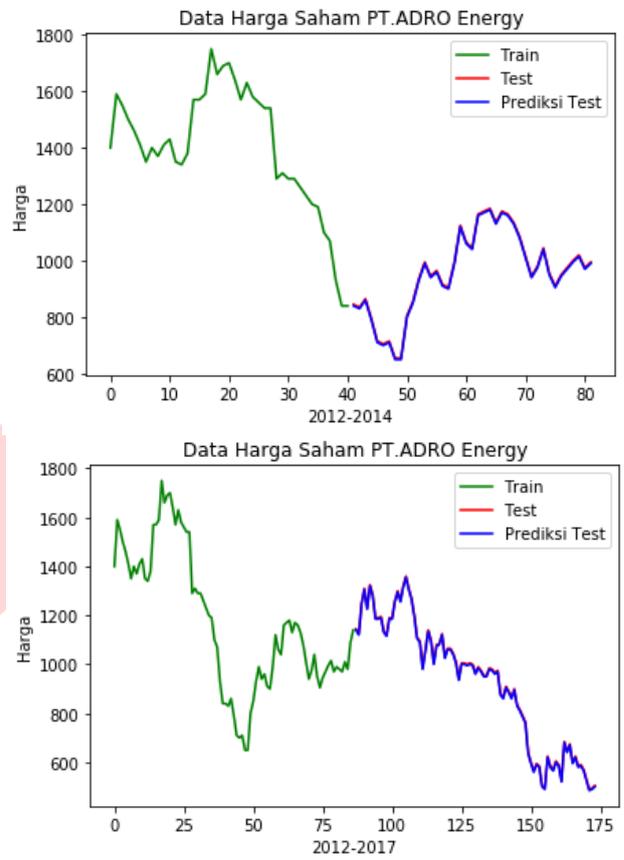
- [1] T. Aamodt, "Predicting Stock Markets with Neural Networks," 2015.
- [2] A. a. Ariyo, A. O. Adewumi, and C. K. Ayo, "Stock Price Prediction Using the ARIMA Model," *2014 UKSim-AMSS 16th Int. Conf. Comput. Model. Simul.*, pp. 106–112, 2014.
- [3] G. M. Isenah, O. E. Olubusoye, and S. M. Returns, "Forecasting Nigerian Stock Market Returns using ARIMA and Artificial Neural Network Models," vol. 5, no. 2, pp. 25–48, 2014.
- [4] M. C. Badias, "Stock market time series forecasting with data mining methods * 1," no. May, pp. 205–225, 2014.
- [5] P. S. Sekar, K. S. Kannan, M. M. Sathik, and P. Arumugam, "Financial stock market forecast using data mining techniques," *Proc. Int. MultiConference Eng. Comput. Sci.*, vol. I, p. 5, 2010.
- [6] A. Bernal, S. Fok, and R. Pidaparathi, "Financial Market Time Series Prediction with Recurrent Neural Networks," pp. 1–5, 2012.
- [7] Y. Zhang, "Prediction of Financial Time Series With Hidden Markov Models," no. May, 2004.

- [8] B. Krollner, B. Vanstone, and G. Finnie, "Financial time series forecasting with machine learning techniques: A survey," 2010.
- [9] P. Arora and D. Hemavathi, "Forecasting of Stock Market through Trends and Patterns using Time Series Analysis," vol. 4, no. 4, pp. 2013–2016, 2015.
- [10] D. Vengertsev, "Deep Learning Architecture for Univariate Time Series Forecasting," *Cs229*, pp. 3–7, 2014.
- [11] M. Längkvist, L. Karlsson, and A. Loutfi, "A review of unsupervised feature learning and deep learning for time-series modeling," *Pattern Recognit. Lett.*, vol. 42, no. 1, pp. 11–24, 2014.
- [12] A. Fischer and C. Igel, "An Introduction to Restricted Boltzmann Machines," *Lect. Notes Comput. Sci. Prog. Pattern Recognition, Image Anal. Comput. Vision, Appl.*, vol. 7441, pp. 14–36, 2012.
- [13] G. Taylor, G. E. Hinton, and S. Roweis, "Modeling human motion using binary latent variables," *Adv. Neural Inf. Process. Syst.*, vol. 19, p. 1345, 2007.
- [14] M. Welling, M. Rosen-zvi, and G. E. Hinton, "Exponential Family Harmoniums with an Application to Information Retrieval," *Adv. Neural Inf. Process. Syst.*, vol. 17, pp. 1481–1488, 2005.
- [15] G. W. Taylor and G. E. Hinton, "Factored conditional restricted Boltzmann Machines for modeling motion style," *Proc. 26th Int. Conf. Mach. Learn. (ICML 09)*, pp. 1025–1032, 2009.
- [16] <https://finance.yahoo.com/quote/adro.jk?ltr=1> diakses pada: 26 Desember 2017.
- [17] Geoffrey E Hinton. "Training products of experts by minimizing contrastive divergence." In: *Neural computation* 14.8 (2002), pp. 1771– 1800.
- [18] Geoffrey Hinton. *A Practical Guide to Training Restricted Boltzmann Machines*. Tech. rep. 2010. URL: <http://www.cs.toronto.edu/~5C~%7B%7Dhinton/absps/guideTR.pdf>.
- [19] Graham. W Taylor, Geoffrey E Hinton, and Sam T Roweis. "Modeling human motion using binary latent variables." In: *Advances in neural information processing systems* 19 (2007), p. 1345.
- [20] <http://www.forecastpro.com/Trends/forecasting101August2011.html> diakses pada 6 januari 2018.
- [21] E.F. Fama, The behavior of stock-market prices, *J. Bus.* 1 (1965) 34–105.
- [22] C.F. Tsai, Y.C. Hsiao, Combining multiple feature selection methods for stock prediction: union, intersection, and multi-intersection approaches, *Decis. Support Syst.* 50 (2010) 258–269.
- [23] B. Malkiel, The efficient market hypothesis and its critics, *J. Econ. Perspect.* 17 (2003). <http://dx.doi.org/10.2307/3216840>.

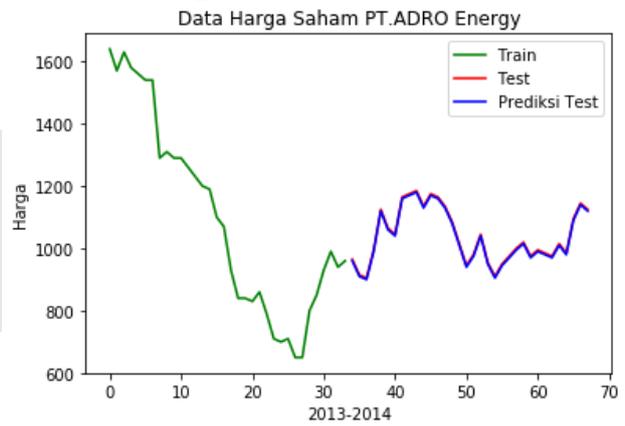
Lampiran

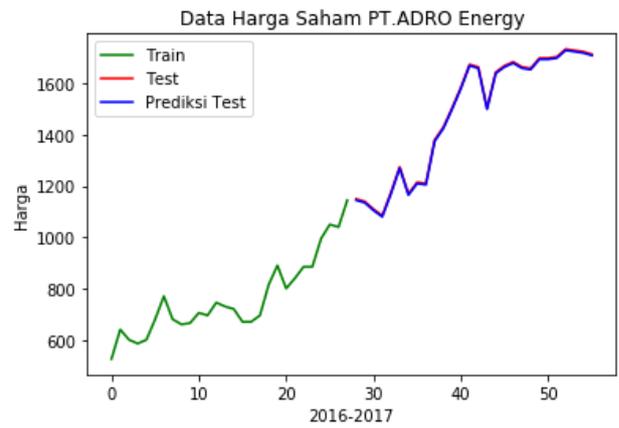
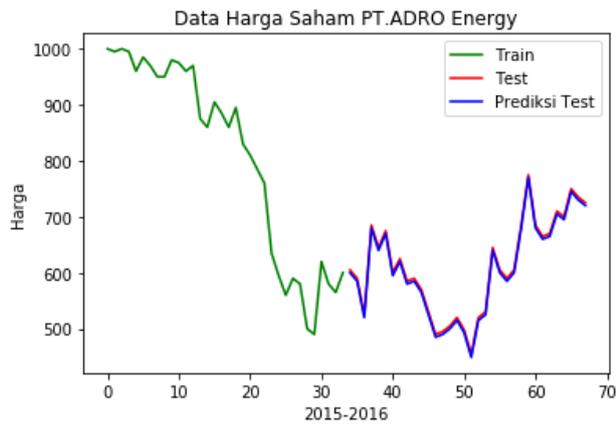


Data Uji



Data Pemandang





Tabel 4.3 Hasil MSE dan MAPE Per-Periode 4 tahun.

Tahun	Jumlah Training	MSE	MAPE
2012-2016	76	89055,59	21,651
2013-2017	80	149848,7	30,578