

Gated Restricted Boltzmann Machines (GRBM) Pada Data Time Series

Gated Restricted Boltzmann Machines (GRBM) In Time Series Data

¹Faisal Hamdani, ²Jondri, M.Si

Ilmu Komputasi Fakultas Informatika, Universitas Telkom, Bandung
¹faisalhamdani.1107112065@gmail.com, ²jondri@telkomuniversity.ac.id,

Abstrak

Prediksi harga saham adalah salah satu kebutuhan yang sangat krusial bagi para investor. Biasanya investor membeli saham untuk mendapatkan keuntungan berdasarkan jumlah saham yang dimiliki yaitu dengan cara membeli suatu saham dengan harga murah dan menjualnya dengan harga yang lebih tinggi. Dengan memprediksi harga saham, pemilik saham dapat membuat keputusan yang tepat dalam melakukan transaksi jual beli saham tersebut. Namun dalam memprediksi harga saham dibutuhkan sistem yang dapat digunakan untuk menghasilkan nilai saham yang akan datang dengan tepat. Pada penelitian ini, metode *Deep Belief Network* dipilih dengan menggunakan tumpukan *Gated Restricted Boltzmann Machine* dengan jumlah neuron latent yang berbeda untuk prediksi harga saham. Pengukuran performansi prediksi saham dilakukan setelah tahap perancangan sistem dilakukan. Dengan menggunakan metode *Deep Belief Network* hasil penelitian sistem prediksi saham mampu memberikan nilai *error* terbaik yaitu RMSE 0,01575 dan MAPE 0.8074 dengan jumlah neuron latent 15.

Kata kunci : prediksi saham, Deep Belief Network, Restricted Boltzmann Machine, Gated Restricted Boltzmann Machine

Abstract

Stock price prediction is one of the most crucial needs for investors. Usually investors buy shares to gain profits based on the number of shares owned by buying a stock at a low price and selling it at a higher price. By predicting stock prices, shareholders can make the right decision in the sale and purchase of such shares. But in predicting stock prices required a system that can be used to generate the value of the stock that will come with the right. In this study, the Deep Belief Network method was selected using the Gated Restricted Boltzmann Machine stack with different latent neuron numbers for stock price predictions. Measurement of stock prediction performance is done after phase of system design stage done. By using Deep Belief Network method result of research of stock prediction system able to give the best error that is RMSE 0,01575 and MAPE 08074 with number of neuron latent 15.

Keywords : Stock Prediction, Deep Belief Network, Restricted Boltzmann Machine, Gated Restricted Boltzmann Machine

1 Pendahuluan

1.1 Latar Belakang

Investasi merupakan salah satu bentuk kegiatan ekonomi yang sangat tren dalam dunia globalisasi saat ini. Investasi memberikan keuntungan cukup menggiurkan bagi para investor. Dibalik keuntungan yang didapat oleh para investor, namun perlu diingat bahwa tidak semua investasi dapat memberi keuntungan[1].

Memprediksi perubahan harga pasar dan membuat keputusan yang tepat adalah salah satu kebutuhan yang sangat krusial bagi para investor. Biasanya investor membeli saham untuk mendapatkan dividen atau pembagian keuntungan kepada pemegang saham berdasarkan jumlah saham yang dimiliki, dengan membeli suatu saham dengan harga murah dan menjualnya dengan harga yang lebih tinggi. Pergerakan pasar saham dipengaruhi oleh banyak faktor mikro-ekonomi seperti peristiwa politik, kebijakan perusahaan, kondisi ekonomi secara umum, komoditas harga, bunga bank, nilai tukar bank, psikologi, dll. Perubahan pada faktor-faktor tersebut menyebabkan ketidakpastian harga saham sehingga dibutuhkan prediksi untuk melihat pergerakan pasar saham di masa depan[1].

Deep Learning merupakan salah satu metode yang dapat digunakan untuk memberikan solusi yang optimal untuk kasus prediksi harga saham. Deep learning merupakan perkembangan dari metode-metode prediksi lainnya seperti metode SVM (Support Vector Machine) dan Machine Learning. Maka pada tugas akhir ini akan dibuat prediksi menggunakan metode Deep learning dengan tumpukan Gated Restricted Boltzmann Machine.

1.2 Rumusan Masalah

Permasalahan yang akan dibahas dalam penelitian ini adalah bagaimana cara melakukan prediksi harga saham dengan menggunakan metode *Deep Belief Network* dengan tumpukan *Gated Restricted Boltzmann Machine* dan menganalisa error dari hasil prediksi saham tersebut.

1.3 Topik dan Batasannya

Dalam penelitian ini penulis menganalisis dan membangun sistem untuk prediksi harga saham yang akan datang, serta mengamati nilai error performansi sistem prediksi saham tersebut. Pada pengerjaan sistem prediksi saham terdapat batasan-batasan masalah yaitu data yang digunakan adalah data saham PT. Telekomunikasi Indonesia. Data tersebut dirubah kedalam bentuk matriks 1 sampai 10 hari sebelumnya untuk dijadikan data training dan target pada penelitian. Penelitian ini dikerjakan menggunakan perangkat lunak MATLAB R2017b.

1.4 Tujuan

Tujuan dari penelitian ini adalah mampu merancang sistem prediksi harga saham yang akan datang dan menganalisis performa sistem prediksi terhadap parameter-parameter yang digunakan.

2 Studi Terkait

1.1 Prediksi Atau Peramalan

Prediksi adalah proses penggambaran sesuatu yang akan terjadi dimasa depan dengan menggunakan data dan informasi saat ini dan sebelumnya. Prediksi memiliki tujuan untuk memberikan gambaran sedekat mungkin dengan apa yang akan terjadi dan tidak memberikan suatu kondisi pasti tentang apa yang akan terjadi. Kunci dalam peramalan adalah membaca sejumlah data untuk menemukan sejumlah karakteristik dan kecenderungan, dengan prinsip bahwa kejadian dimasa lalu akan berulang dimasa depan[2].

1.2 Prediksi *Time series*

Prediksi secara *time series* merupakan peramalan yang dilakukan dengan menggunakan data tertentu yang disebut data *time series*. Data *time series* adalah nilai suatu variabel yang disusun berdasarkan urutan/deret waktu bisa dalam satuan harian, mingguan, bulanan, atau tahunan tergantung keperluan terhadap perilaku data yang akan diobservasi. Data *time series* yang digunakan adalah data historis yang diukur berdasarkan suatu pengamatan tertentu. Karena data yang digunakan adalah data yang terukur, maka peramalan secara *time series*, termasuk ke dalam peramalan kuantitatif. Metode prediksi *time series* beranggapan bahwa data atau kejadian masa lalu akan cenderung berulang dimasa yang akan datang. Fokus prediksi secara *time series* adalah apa yang akan terjadi, bukan mengapa hal itu terjadi[3].

1.3 *Deep Learning*


Deep Learning (deep machine learning, or deep structured learning, or hierarchical learning) adalah cabang dari machine learning berdasarkan satu set algoritma yang digunakan untuk model abstraksi tingkat tinggi pada data dengan menggunakan beberapa lapisan implementasi dan menggunakan struktur yang kompleks atau sebaliknya, terdiri dari beberapa transformasi non-linear. Teknik dan algoritma dalam *Deep Learning* dapat digunakan baik untuk kebutuhan supervised learning, unsupervised learning dan semi-supervised learning dalam berbagai aplikasi seperti pengenalan citra, pengenalan suara, klasifikasi teks. Model *Deep* pada dasarnya dibangun berdasarkan Jaringan saraf tiruan dan dapat melakukan kalkulasi berbasis matriks secara simultan[4].

2.4 *Deep Belief Network (DBN)*

Deep Belief Network dibangun oleh tumpukan *Restricted Boltzmann Machines*. Dari urutan training dan pembuatan layer, kita dapat membangun sebuah kedalaman Neural Network. Sekali stack dari *Restricted Boltzmann Machines* yang ditrain, dapat digunakan untuk menginialisasi sebuah multilayer neural network. Untuk mengerti bagaimana pengerjaan mesin learning ini kita memerlukan teori pendukung dari *Restricted Boltzmann Machines* [4][5].

2.5 *Restricted Boltzmann Machines (RBM)*

Restricted Boltzmann Machines adalah jaringan neuron yang terdiri dari dua layer yaitu *visible layer* dan *hidden layer*. *Visible layer* mewakili data yang terkumpul saat *hidden layer* mencoba mempelajari fitur dari *visible layer* yang bertujuan untuk mewakili distribusi probabilitas data. *Visible layer* dan *hidden Layer* terhubung dengan bobot (W) dan memiliki masing-masing bias vector (b dan c). Jaringan Network ini disebut *Restricted* karena *visible layer* hanya memiliki koneksi ke *hidden layer*, tidak ada koneksi antar neuron di *visible* dan *hidden layer*. Hubungan ini memungkinkan untuk transfer informasi dua arah[5][6].



Gambar 2.1 Restricted Boltzmann Machine

Pada RBM hidden unit dapat dilihat sebagai sifat *detector* jaringan yang menetapkan sebuah probabilitas kesetiap pasangan dari visible dan hidden unit sesuai dengan distribusinya.

$$p(v, h) = \frac{1}{Z} e^{-E(v,h)} \tag{1}$$

Yang dimana fungsi partisinya diberikan oleh $Z = \sum_{v,h} e^{-E(v,h)}$


Fungsi energi dari *RBM* tersebut dapat ditulis sebagai berikut:

$$E(v, h) = - \sum_{ij} W_{ij} v_i h_j - \sum_i b_i v_i - \sum_j c_j h_j \tag{2}$$

Dimana dalam persamaan ini v dan h adalah visible layer dan hidden layer, b_i dan c_j adalah bias dari visible layer dan hidden layer dan W adalah bobot dari interaksi antara unit i dan j , di visible dan hidden layer.

2.6 Gated Restricted Boltzmann Machine (GRBM)

Secara khusus Gated RBM adalah perluasan atau ekstensi lain dari RBM yang modelnya transisinya antara dua masukan yaitu input dan output . Gated RBM terdiri dari tiga lapisan yaitu input layer, output layer dan latent variable. Latent variable menghitung probabilitas dari input layer dan dikonversi menjadi output layer. Disebut gated karena latent layer dianggap sebagai gerbang untuk menemukan hasil dari konversi input layer menjadi output layer[7][8].



Gambar 2.2 Gated Restricted Boltzmann Machine

Fungsi dari Gated RBM tersebut dapat ditulis sebagai berikut:

$$E(y, z; v) = - \sum_{ijk} W_{ijk} v_i y_j z_k - \sum_k b_k z_k - \sum_j c_j y_j \quad (3)$$

Dimana dalam persamaan ini v, z dan y adalah visible layer, latent variable layer dan output layer. b_k dan c_j adalah bias dari latent layer dan output layer dan W adalah bobot dari interaksi antara unit i dan j , di visible dan latent layer.

Dari transformasi antara v dan y , dengan menggunakan fungsi energy dari setiap konfigurasi $p(y, h|v)$ dikonversikan menjadi probabilitas bersyarat dengan normalisasi sebagai berikut yaitu:

$$p(y, z|v) = \frac{1}{Z(v)} \exp(-E(y, z|v)) \quad (4)$$

Dimana fungsi partisinya diberikan oleh: $Z(v) = \sum_{y,h} \exp(-E(y, z; v))$

Fungsi energy dari GRBM tersebut mengandung interaksi antara 3 unit satuan yaitu v, y dan z , tetapi tidak antara pasangan unit output dan unit latent. Sehingga didapat kondisional probabilitas atau pembeda seperti pada RBM yang dapat menyederhanakan pembelajaran dan kesimpulan untuk memudahkan sampling gibbs yang efisien[5].

Dari persamaan tersebut didapat distribusi probabilitas sebagai berikut:

$$p(z_k = 1|y; v) = \sigma \left(\sum_{i,j} W_{ijk} v_i y_j + b_k \right) \quad (5)$$

$$p(y_i = 1|z; v) = \sigma \left(\sum_{i,k} W_{ijk} v_i z_k + c_j \right) \quad (6)$$

Dari persamaan diatas dapat dilihat bahwa nilai z_k dan y_i akan bernilai satu jika setiap hasil dari proses perhitungan dalam mencari nilai peluang masing – masing layer lebih besar dari nilai awal random yang telah ditentukan di awal training program. Fungsi dari persamaan ini adalah sebagai pembeda dari setiap proses training dalam prediksi menggunakan *Gated Restricted Boltzmann Machine*.

Karena proses pada Gated RBM adalah dengan mentransformasikan input data menjadi output data, maka proses tersebut tidak mencoba memodelkan input data itu sendiri. Learning pada Gated RBM tersebut sama dengan RBM biasa, namun dalam menghitung probabilitas aktivasi masing – masing node membutuhkan komputasi ekstra yang substansial karena setiap keluaran dari latent layer menerima masukan dari setiap input layer[7][8].

3 Rancangan Sistem

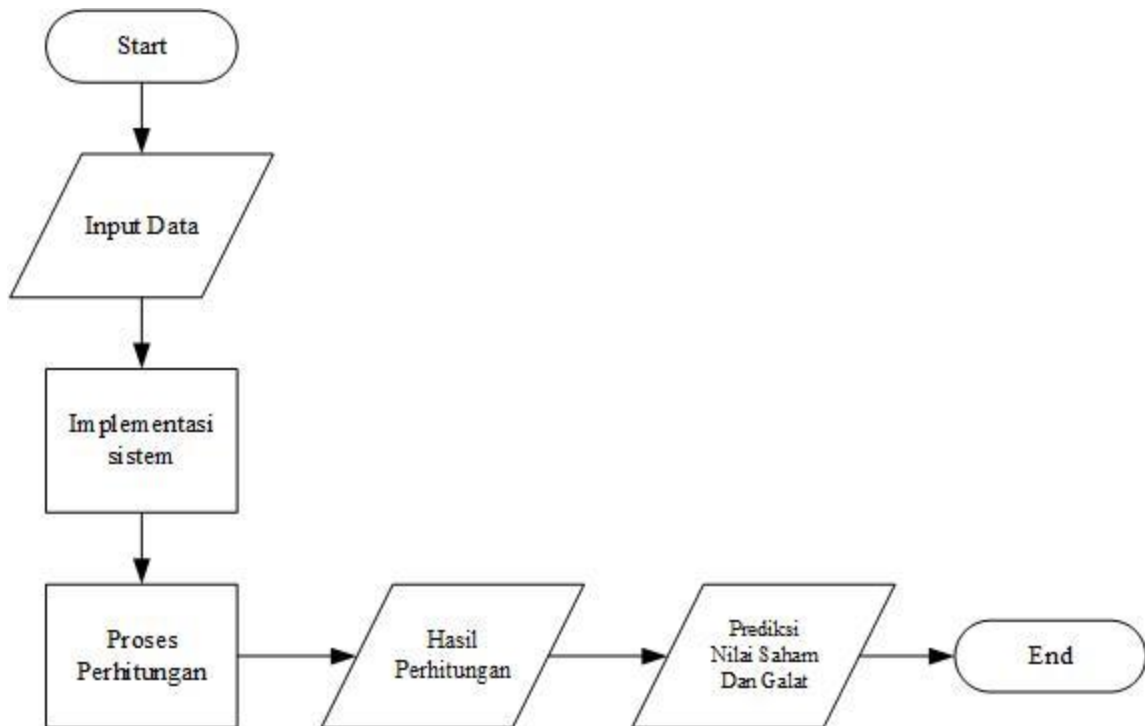
3.1 Deskripsi Sistem

Pada tugas akhir ini akan dirancang sebuah sistem untuk menyelesaikan masalah prediksi saham dengan metode *Deep Belief Network* dengan tumpukan *Gated Restricted Boltzmann Machine* dalam menemukan nilai saham yang akan datang.

3.2 Perancangan Sistem

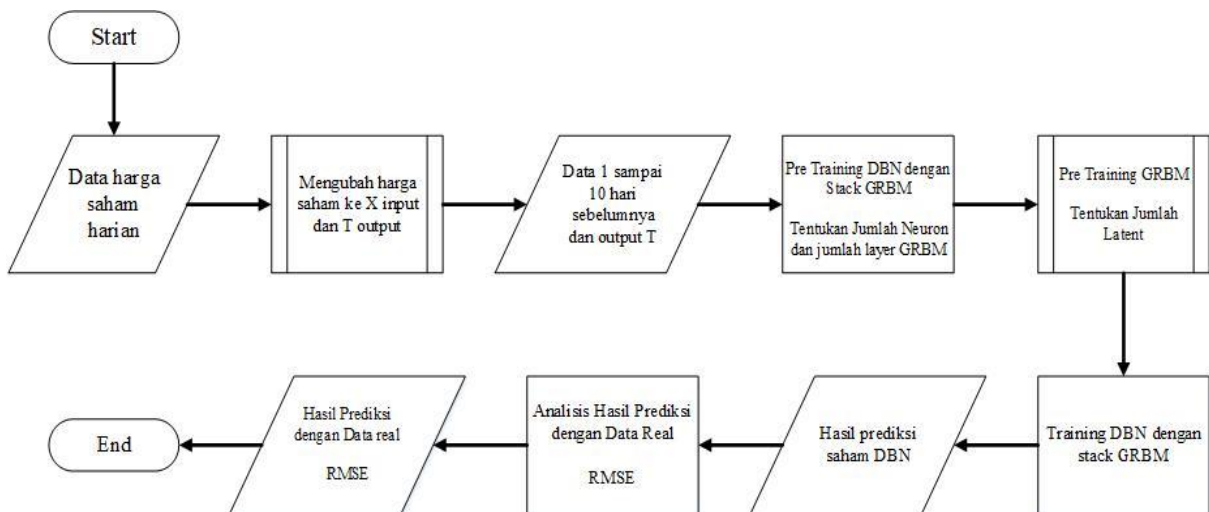
Alur dari perancangan sistem *Deep Belief Network* dengan tumpukan *Gated Restricted Boltzmann Machine* dijelaskan sebagai berikut:

1. Input data, yaitu melakukan input data kedalam algoritma. Data yang diinputkan sudah dirubah kedalam bentuk matriks 1 sampai 10 hari sebelumnya.
2. Implementasi sistem, dijabarkan pada subbab selanjutnya.
3. Proses perhitungan, yaitu menghitung masing masing GRBM pada implementasi system.
4. Hasil Prediksi, yaitu proses yang menghasilkan prediksi dari proses perhitungan implementasi system.
5. Prediksi saham dan nilai galat, yaitu hasil dari implementasi system dan membandingkan hasil GRBM terbaik dalam prediksi saham.



Gambar 3.1 Flowchart Perancangan Sistem

3.3 Implementasi sistem



Gambar 3.2 Flowchart Sistem Prediksi DBN dengan tumpukan GRBM

Alur dari implementasi sistem prediksi *Deep Belief Network* dengan tumpukan *Gated Restricted Boltzmann Machine* yang dibangun dijelaskan sebagai berikut:

1. Tahap pertama, *visible layer* (input layer) yaitu data harga saham dirubah ke dalam bentuk matriks 1 sampai 10 hari sebelumnya untuk dijadikan data training X pada proses prediksi dan target T untuk dijadikan data pembanding antara nilai real dengan nilai prediksi yang dihasilkan.
2. Tahap kedua, *latent layer* yaitu membuat jumlah layer *Gated Restricted Boltzmann Machine* (GRBM) yang dipakai dengan jumlah nilai neuron pada masing – masing layer GRBM.
3. Tahap ketiga, *output layer* yaitu analisa nilai prediksi saham dengan hasil yang dipengaruhi oleh *visible layer* dan *latent layer*.



4 Evaluasi

4.1 Hasil Pengujian

Seperti yang telah dijelaskan pada bab sebelumnya, Tugas Akhir ini bertujuan untuk menerapkan metode DBN dengan menumpuk 2 *Gated Restricted Boltzmann Machine* pada prediksi saham harian PT. Telekomunikasi Indonesia. Pada tahap pertama yaitu memprediksi nilai saham menggunakan 1 sampai 10 hari data sebelumnya, kemudian setiap tahap prediksi menggunakan 2 *Gated Restricted Boltzmann Machine* dengan neuron latent yang berbeda yaitu 5, 10 dan 15. Hasil prediksi akan di bandingkan untuk menghasilkan nilai lebih baik. Berikut adalah hasil dari proses implementasi sistem prediksi saham.

Tabel 4.1 : Hasil prediksi skenario 1 dengan jumlah data 1 sampai 10 dan nilai *error* RMSE dan MAPE.

Skenario 1	DBN Stack GRBM		
	Data Hari Sebelumnya	RMSE	MAPE
Latent = 5	1	0.01669	0.9832
	2	0.02025	0.9541
	3	0.01636	0.8749
	4	0.01665	0.8534
	5	0.01687	0.8645
	6	0.01643	0.8856
	7	0.01622	0.8634
	8	0.01658	0.8595
	9	0.01644	0.8404
	10	0.01602	0.8404




Gambar 4.1: grafik prediksi skenario 1 dengan neuron latent = 5

Semakin kecil nilai *error* maka hasil dari prediksi saham semakin jelas. Pada skenario 1, hasil dari nilai *error* terkecil diperoleh oleh data 10 hari sebelumnya yaitu RMSE 0.01602 dan MAPE 0.8404. Dari grafik prediksi nilai *error*, dapat dilihat bahwa tidak ada penurunan trend yang signifikan dari nilai errornya sedangkan dari hasil grafik data real dengan data prediksi dapat dilihat bahwa hasil dari data prediksi hampir sama dengan data realnya

Tabel 4.2 : Hasil prediksi skenario 2 dengan jumlah data 1 sampai 10 dan nilai error RMSE dan MAPE.

Skenario 2	DBN Stack GRBM		
	Data Hari Sebelumnya	RMSE	MAPE
Latent = 10	1	0.01727	0.8138
	2	0.01718	0.8245
	3	0.01640	0.8349
	4	0.01658	0.8134
	5	0.01629	0.8145
	6	0.01668	0.8256
	7	0.01696	0.8134
	8	0.01653	0.8195
	9	0.01641	0.8194
	10	0.01602	0.8079




Gambar 4.2: grafik prediksi skenario 2 dengan neuron latent = 10

Pada skenario 2, hasil dari nilai error terkecil diperoleh oleh data 10 hari sebelumnya yaitu RMSE 0.01602 dan MAPE 0.8079. Dari grafik prediksi nilai error, dapat dilihat bahwa ada penurunan trend yang tidak terlalu signifikan karena adanya kenaikan nilai RMSE di data 6 dan 7 hari sebelumnya sedangkan dari hasil grafik data real dengan data prediksi dapat dilihat bahwa hasil dari data prediksi hampir sama dengan data realnya.

Tabel 4.3 : Hasil prediksi skenario 2 dengan jumlah data 1 sampai 10 dan nilai error RMSE dan MAPE.

Skenario 3	DBN Stack GRBM		
	Data Hari Sebelumnya	RMSE	MAPE
Latent = 15	1	0.01656	0.8854
	2	0.01648	0.8598
	3	0.01647	0.8552
	4	0.01659	0.8432
	5	0.01662	0.8145
	6	0.01674	0.8235
	7	0.01669	0.8134
	8	0.01651	0.8102
	9	0.01629	0.8098
	10	0.01575	0.8074



Gambar 4.3: grafik prediksi skenario 3 dengan neuron latent = 15

Pada skenario 3, hasil dari nilai *error* terkecil diperoleh oleh data 10 hari sebelumnya yaitu RMSE 0.01575 dan MAPE 0.8074. Dari grafik prediksi nilai *error*, dapat dilihat bahwa ada penurunan trend yang signifikan dari data 6 sampai 10 hari sebelumnya sedangkan dari hasil grafik data real dengan data prediksi dapat dilihat bahwa hasil dari data prediksi hampir sama dengan data realnya.

5 Kesimpulan

Berdasarkan hasil dan analisis pengujian sistem prediksi saham PT. Telekomunikasi Indonesia yang telah dilakukan, dapat disimpulkan bahwa:

1. Nilai *error* terkecil diperoleh pada data 10 hari sebelumnya dengan jumlah neuron latent 15 yaitu RMSE 0.01575 dan MAPE 0.8074. Hal ini disebabkan oleh faktor dari jumlah neuron latent dan data saham yang dijadikan training dalam proses perhitungan banyak. Maka hasil dari nilai *error* prediksi dan grafik perbandingan akan semakin mendekati nilai aslinya.
2. Jumlah neuron latent dan neuron visible mempengaruhi hasil dari nilai RMSE prediksi saham tersebut. Semakin banyak jumlah neuron latent dan neuron visible maka hasil prediksi akan semakin baik. Untuk penentuan seberapa besar jumlah neuron latent dan visible cukup menggunakan satu skenario saja, karena dengan jumlah neuron yang banyak maka hasil akan semakin baik.

Daftar Pustaka

- [1] "Repository Universitas Sumatera Utara : Saham," [Online]. Available: <http://repository.usu.ac.id/bitstream/123456789/27690/4/Chapter%20II.pdf>. [Diakses 4 8 2017].
- [2] "Repository Univesitas Sumatera Utara : Prediksi," [Online]. Available: <http://repository.usu.ac.id/bitstream/123456789/42955/8/Chapter%20I.pdf>. [Diakses 4 8 2017].
- [3] Ashari, Ashari. "Penerapan Metode Times Series Dalam Simulasi Forecasting Perkembangan Akademik Mahasiswa." *Jurnal Inspiration* 3.2 (2013).
- [4] Huang, H.B., Li, R.X., Yang, M.L., Lim, T.C. and Ding, W.P., 2017. Evaluation of vehicle interior sound quality using a continuous restricted Boltzmann machine-based DBN. *Mechanical Systems and Signal Processing*, 84, pp.245-267.
- [5] Långkvist, M., Karlsson, L. and Loutfi, A., 2014. A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern Recognition Letters*, 42, pp.11-24.
- [6] Hrasko, R., Pacheco, A.G. and Krohling, R.A., 2015. Time series prediction using restricted Boltzmann machines and backpropagation. *Procedia Computer Science*, 55, pp.990-999.
- [7] Bebbington, James. "Learning Actions that Reduce Variation in Objects." (2011).
- [8] Taylor, G., Fergus, R., LeCun, Y. and Bregler, C., 2010. Convolutional learning of spatio-temporal features. *Computer Vision-ECCV 2010*, pp.140-153.