

GENERAL REGRESSION NEURAL NETWORK (GRNN) PADA PERAMALAN KURS DOLAR DAN INDEKS HARGA SAHAM GABUNGAN (IHSG)

Luh Putu Widya Adnyani¹, Subanar²

¹Program Studi Teknik Informatika Fakultas Teknik Matematika dan Ilmu Pengetahuan Alam Universitas Indraprasta PGRI, Jakarta, Indonesia

²Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Gadjah Mada, Yogyakarta, Indonesia

Korespondensi: e-mail:widya_nesia@yahoo.com, e-mail:subanar@yahoo.com

Abstrak

General Regression Neural Network (GRNN) merupakan salah satu metode yang dikembangkan dari konsep jaringan syaraf tiruan yang dapat digunakan untuk peramalan. Metode ini diaplikasikan untuk memprediksi data time series yang memiliki hubungan kausal dimana metode peramalan yang digunakan sebelumnya (ARIMA BOX - Jenkins) tidak mampu menjelaskan adanya keterkaitan data.

Penelitian ini dilakukan dengan mengambil data kurs dollar dan IHSG. Dengan menggunakan metode GRNN diperoleh suatu prediksi nilai IHSG beberapa periode kedepan. Keunggulan penggunaan metode ini yaitu lebih cepat dari segi perhitungan dan tidak memerlukan adanya suatu asumsi data. Metode GRNN menghasilkan nilai prediksi yang lebih akurat dibandingkan dengan metode ARIMA. Hal itu ditunjukkan dari nilai MSE yang lebih kecil dari metode ARIMA.

Kata Kunci: GRNN, Neural Network, GRNN Time Series, GRNN Kurs dan IHSG.

Abstract

General Regression Neural Network (GRNN) is one method that was developed from the concept of artificial neural network that can be used for forecasting. This method was applied to predict the time series data that has a causal relations where the forecasting method used previously (ARIMA BOX-Jenkins) is not able to explain the presence of linkage data.

This research was conducting by taking the dollar exchange rate and composite stock price index (IHSG). By using the GRNN method will obtained the predictive value in some future period. The advantages using this method is faster in term of computation and doesn't required the presence of a data assumptions. GRNN method produces more accurate predictive value compared with ARIMA. It was shown that the MSE value is smaller than ARIMA.

Keyword: GRNN, Neural Network, GRNN Time Series, GRNN Dollar exchange rate and IHSG.

PENDAHULUAN

IHSG digunakan sebagai indeks atau indikator pergerakan saham. Apabila saham naik, maka banyak investor yang menanamkan modalnya di bursa saham. Banyak hal yang mempengaruhi harga saham di pasaran antara lain: situasi politik suatu negara, kurs dollar,

suku bunga dan inflasi, harga minyak dunia serta harga emas dunia. Salah satu dampak dari krisis global adalah melemahnya nilai tukar rupiah terhadap dollar.

Permasalahan yang muncul kemudian adalah bagaimana memprediksi IHSG berdasarkan kurs dollar. Pada awalnya metode yang sering digunakan dalam peramalan adalah ARIMA Box – Jenkins. Metode ini memiliki keterbatasan yaitu mengabaikan kemungkinan hubungan non linear serta *stationeritas* data dan *homokedastisitas* residual. Kini metode peramalan untuk data *time series* telah berkembang salah satunya adalah dengan menggunakan algoritma jaringan saraf tiruan atau dikenal dengan nama *Neural Network* (NN).

General Regression Neural Network (GRNN) merupakan pengembangan dari Neural Network. GRNN dikembangkan oleh Specht dan Leung. Model ini banyak diterapkan untuk peramalan data *time series* dan banyak juga digunakan untuk berbagai masalah statistika baik dengan *output* multivariat ataupun univariat.

Dari uraian latar belakang tersebut, permasalahan yang dibahas secara umum adalah bagaimana memprediksi nilai IHSG berdasarkan nilai kurs dollar untuk beberapa periode mendatang, melihat grafik *insample* dan *outsample* serta membandingkan hasil prediksi IHSG dengan metode terdahulu.

Penelitian yang Pernah Dilakukann

Metode GRNN pertama kali dikembangkan oleh Specht. Penelitian dengan menggunakan GRNN pernah dilakukan oleh Leung (2000) untuk memprediksi beberapa nilai tukar mata uang dan membandingkan dengan metode JST yang lain.

LANDASAN TEORI

Konsep Dasar Analisis Time Series

Analisis *time series* merupakan suatu metode peramalan dengan data yang dipengaruhi oleh waktu. Data tersebut berada pada suatu interval yang sama. Misalnya : harian, mingguan, bulanan dan tahunan. Peramalan *time series* yaitu memprediksi nilai mendatang berdasarkan pada data – data masa lalu. Secara umum menurut Cryer (1986), nilai pengamatan untuk data *time series* dilambangkan Z_t dengan t merupakan periode waktu. Peramalan dengan *time series* dengan metode klasik harus memenuhi beberapa asumsi. Salah satu asumsi awal yang harus dilalui dalam langkah analisis *time series* tersebut adalah kestasioneran data. *Statoner* adalah keadaan dimana suatu data memiliki nilai tengah dan varians yang konstan. Kestasioneran suatu data diperlukan mengingat data yang terjadi di lapangan dapat dilihat secara visual ataupun dengan uji ADF (Augmented Dickey Fuller).

Stasioner tidaknya suatu data secara visual dapat dilihat dari plot ACF dan PACF. Data dikatakan *stasioner* apabila nilai – nilai ACF dan PACF nya turun sampai dengan nol setelah time lag ke – 2 atau ke – 3, sedangkan untuk data yang tidak *stasioner* nilai tersebut berbeda dari nol untuk beberapa periode waktu. Dilihat dari uji ADF data dikatakan *stationer* apabila nilai statistik uji lebih besar dari nilai kritis.

Artificial Neural Network

Artificial neural network (ANN) atau jaringan saraf tiruan (JST) merupakan sistem komputasi dimana arsitektur dan operasi diilhami dari pengetahuan tentang sel saraf biologis di dalam otak, yang merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba menstimulasi proses pembelajaran pada otak manusia tersebut (Hermawan, 2006).

JST dapat diklasifikasikan menjadi dua bagian berdasarkan cara menyimpan pengetahuan(*encode*) yaitu JST *supervised* dan *unsupervised*. JST dengan *supervised* biasanya digunakan untuk peramalan ataupun pengenalan objek sedangkan untuk JST *unsupervised* digunakan untuk pengelompokan atau *clustering*.

JST semakin berkembang dan aplikasi JST banyak dimanfaatkan untuk berbagai kepentingan di berbagai bidang. Pada bidang financial JST dapat digunakan untuk analisis keuangan ataupun peramalan harga mata uang. FFNN dan GRNN merupakan bagian dari NN yang dapat digunakan pada peramalan data deret waktu.

Jaringan Basis Radial

Konsep dasar jaringan basis radial adalah nilai *input* yang akan diolah oleh fungsi aktivasi bukan merupakan hasil penjumlahan terbobot dari data input, namun berupa vektor jarak antara vektor bobot dan vektor input yang dikalikan dengan bobot bias. Fungsi aktivasi yang digunakan adalah:

$$\text{radbas}(n) = e^{-n^2}.$$

Regresi Kernel

Regresi kernel merupakan teknik estimasi berdasarkan data yang dimiliki. Ide regresi kernel adalah menempatkan suatu set fungsi tertimbang identik yang disebut kernel lokal untuk setiap titik data pengamatan. Kernel akan menetapkan bobot untuk setiap lokasi berdasarkan jarak dari titik data dengan fungsi Gaussian yang dapat ditulis sebagai berikut:

$$K_{\alpha}(x, X) = \exp\left(-\frac{(x - X)^2}{2\alpha^2}\right) \quad (1)$$

Dimana x merupakan jangkauan, X adalah nilai data X dan α merupakan konstanta. Regresi kernel bertujuan mengestimasi nilai Y berdasarkan nilai X .

PEMBAHASAN

General Regression Neural Network

GRNN merupakan salah satu model jaringan radial basis yang sering digunakan untuk pendekatan suatu fungsi. Metode ini digunakan untuk prediksi dimana variable outputnya dimodelkan berdasarkan minimal satu variable input. GRNN didasarkan pada teori regresi non linear (Kernel) yang diformulasikan sebagai berikut:

$$E [y |X] = \frac{\int_{-\infty}^{\infty} y f (X , y) dy}{\int_{-\infty}^{\infty} f (X , y) dy} \quad (2)$$

Dimana y merupakan output yang diprediksi oleh GRNN, sedangkan X merupakan vektor input (x_1, x_2, \dots, x_p) yang terdiri dari p variabel. $E [y |X]$ merupakan nilai harapan dari output y jika diberikan vektor input X , dan $f(X, y)$ merupakan fungsi densitas probabilitas bersama dari X dan y .

Estimasi PDF yang dibentuk GRNN berdasarkan pada sampel acak. Parzen mengembangkan metode yang lebih simple dalam penentuan PDF pada populasi dari sampel random. Inti dari estimator PDF adalah faktor smoothing. Dengan berbagai factor smoothing berdasarkan pada beberapa tipe prosedur meminimalan error, error minimum antara output prediksi dan output actual dapat diperoleh. Over training dapat dicegah dengan membagi seluruh data menjadi data training dan data testing.

Penafsiran GRNN dapat dibagi menjadi tiga bentuk yaitu: perbandingan tiap variable final smoothing factor, pengukuran model goodness of fit, dan analisis visual. Analisis visual yang dimaksud adalah mengukur hubungan variable input dan variable output. Metode akhir pada analisis output dari GRNN adalah menghitung keakuratan prediksi dengan menghitung persen variansi pada variable output yang diterangkan oleh variable input dengan menghitung MSE.

Pada persamaan (2) diasumsikan bahwa $f(x, y)$ merupakan pdf kontinu yang telah diketahui dari vektor random variabel x , skalar random variabel y . Ketika densitas $f(x, y)$ tidak diketahui, maka dilakukan estimasi. Estimator probabilitas $\hat{f}(x, y)$ berdasarkan nilai sampel X^i dan Y^i pada variabel random x , dan y , dimana n adalah jumlah observasi dan p merupakan dimensi pada variabel vektor x , yang dapat ditulis sebagai berikut:

$$\hat{f}(X, Y) = \frac{1}{(2\pi)^{\frac{(p+1)}{2\sigma^2}}} \cdot \frac{1}{n} \sum_{i=1}^n \exp\left[-\frac{(X-X^i)^T(X-X^i)}{2\sigma^2}\right] \cdot \exp\left[-\frac{(Y-Y^i)}{2\sigma^2}\right] \quad (3)$$

Dengan mensubstitusi persamaan (3) ke persamaan (2) maka diperoleh:

$$\hat{Y}(X) = \frac{\sum_{i=1}^n \exp\left[-\frac{(X-X^i)^2}{2\sigma^2}\right] \int_{-\infty}^{\infty} y \exp\left[-\frac{(y-Y^i)^2}{2\pi^2}\right] dy}{\sum_{i=1}^n \exp\left[-\frac{(X-X^i)^2}{2\sigma^2}\right] \int_{-\infty}^{\infty} \exp\left[-\frac{(y-Y^i)^2}{2\pi^2}\right] dy} \tag{4}$$

Dengan memisalkan $D_i^2 = (X - X^i)^2 + (Y - Y^i)^2$ maka diperoleh hasil integrasi sebagai berikut:

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y^i \exp\left[-\frac{D_i^2}{2\sigma^2}\right]}{\sum_{i=1}^n \exp\left[-\frac{D_i^2}{2\sigma^2}\right]} \tag{5}$$

Struktur dan Arsitektur GRNN

GRNN terdiri dari empat lapisan pemrosesan yaitu: lapisan pertama disebut neuron input, lapisan kedua yaitu neuron pola, lapisan ketiga dikenal dengan nama *summation neuron* dan yang terakhir dinamakan neuron output. Tiap lapisan memiliki peran tersendiri.

Neuron input yang terletak pada lapisan pertama berfungsi sebagai penerima *signal* yang masuk atau menerima informasi. Informasi ini kemudian diteruskan ke neuron pola. Di dalam neuron pola informasi yang didapat dari neuron input akan diproses secara sistematis dengan suatu fungsi aktivasi. Output dari proses ini dilanjutkan ke lapisan berikutnya yaitu neuron *summation*. Pada tahap ini unit – unit pelatihan terbagi menjadi dua bagian untuk menyelesaikan dua tipe *summation* yaitu: *simple arithmetic summation* dan *weighted summation*. Jumlahan dari neuron – neuron *summation* dilanjutkan ke lapisan terakhir yaitu neuron output. Pada lapisan ini hasil bagi dari *simple arithmetic summation* dan *weighted summation* merupakan output GRNN yang dilambangkan dengan *y*.

Pada lapisan ke-2 terdapat suatu fungsi aktivasi yang disimbolkan dengan θ_i . Formula dari fungsi aktivasi tersebut adalah sebagai berikut:

$$\theta_i = e^{-\frac{(x - u_i)^2}{2\sigma^2}} \quad \theta_i = e^{-(x-u_i)^2/2\sigma^2} \tag{6}$$

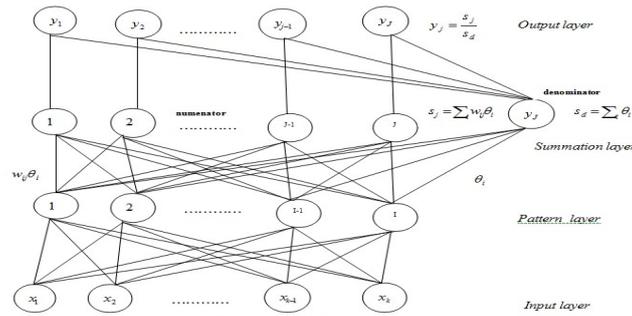
Dimana *X* merupakan vektor input dari variabel prediktor untuk GRNN, *U_i* adalah vektor pelatihan yang diwakili neuron pola *i* dan σ adalah parameter penghalus.

Pada lapisan ke-3 terdapat dua tipe summation yaitu *simple arithmetic summation* dan *weighted summation* yang masing – masing dilambangkan dengan *S_s* dan *S_w*. Adapun formula dari masing – masing summation ini yaitu:

$$S_s = \sum_i \theta_i \tag{7}$$

$$S_w = \sum_i W_i \theta_i \tag{8}$$

Dimana θ_i merupakan output dari lapisan ke-dua sedangkan *W_i* merupakan bobot ke-*i*. Penjelasan di atas dapat dibuat suatu bentuk arsitektur GRNN sebagai berikut:



Gambar 5. Konstruksi GRNN

Algoritma GRNN

Algoritma GRNN dapat ditulis sebagai berikut:

1. Mencari D_{ij} (jarak data ke-i dengan data ke-j). Dimana $i,j = 1,2,3,\dots,Q$

$$D_{ij} = \sqrt{\sum_{k=1}^R (p_{ik} - p_{jk})^2}$$

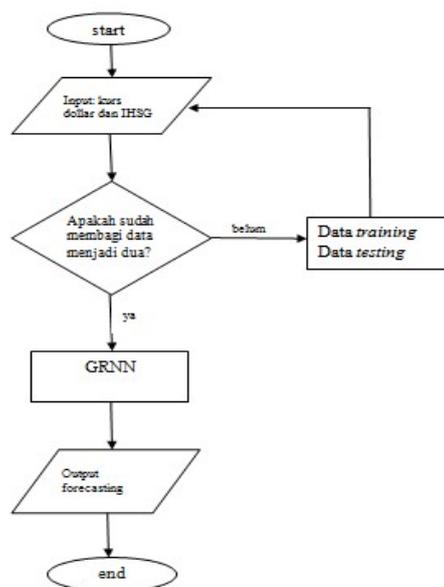
2. Mencari a_{ij} = hasil aktivasi dengan fungsi basis radial dari jarak data dikalikan bias.

Dimana $a_{ij} = e^{-(b_1 * D_{ij})^2}$ dengan $b_1 = \frac{0.8326}{spread}$.

Spread adalah penyebaran data yang nilainya merupakan bilangan real positif.

3. Mencari bobot lapisan dan bobot bias lapisan.
4. Diperoleh output
5. Membandingkan data training dengan data testing.
6. *Forecasting*

Flowchart GRNN:



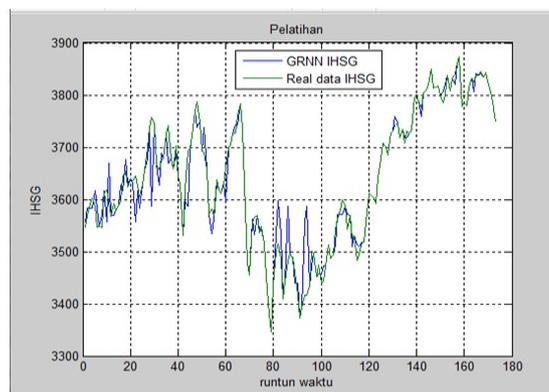
IMPLEMENTASI DAN PEMBAHASAN

Data

Data yang digunakan adalah data IHSG dan nilai kurs dollar terhadap rupiah. Data tersebut berjumlah 247 data dan merupakan data harian. Tahap awal dari proses GRNN adalah membagi data menjadi dua yaitu sebagai data *training* dan data *testing*. Data yang digunakan sebagai data *training* sebanyak 70% dari data keseluruhan dan sisanya digunakan sebagai data *testing*. Hasil prediksi data *training* disebut prediksi *insample* sedangkan hasil prediksi dengan data *testing* disebut prediksi *outsample*.

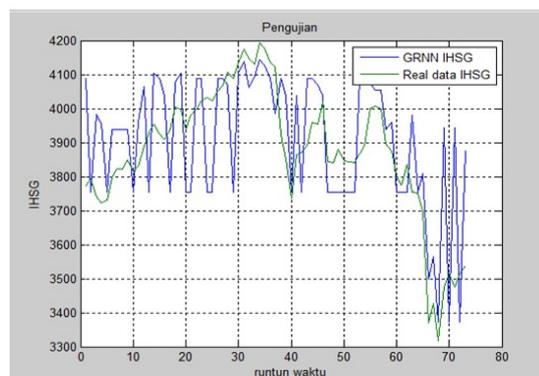
Peramalan GRNN

Peramalan dengan metode GRNN menggunakan bantuan *software* MATLAB. Perintah “newgrnn” digunakan untuk menggenerate jaringan GRNN sehingga dihasilkan prediksi *insample* dan *outsample* sebagai berikut:



Gambar 1. Grafik Prediksi *insample* IHSG

Berdasarkan gambar 1 dapat dilihat bahwa data prediksi yang diwakilkan oleh garis biru mengikuti pola data asli. Prediksi tersebut menghasilkan nilai MSE sebesar 0,0136.



Gambar 2. Grafik Prediksi *Outsample* IHSG

Pola yang ditunjukkan dari data prediksi hampir menyerupai data asli. Grafik di atas menghasilkan nilai MSE sebesar 0,1353. Berikut akan dilakukan beberapa pengujian spread sebagai pembanding nilai MSE.

Tabel 1. Nilai Spread

No	Spread	MSE	
		Training	Testing
1	0,0001	0,0136	0,1976
2	0,001	0,0136	0,1353
3	0,01	0,0430	0,1695
4	0,1	0,073	0,1364
5	0,125	0,0782	0,1320
6	0,15	0,0829	0,1283
7	0,2	0,0902	0,1224
8	0,225	0,0932	0,1197
9	0,25	0,0961	0,1169
10	0,3	0,1015	0,1110

Berdasarkan tabel di atas, nilai spread 0,001 menghasilkan nilai MSE terkecil sehingga untuk tahap peramalan tiga periode kedepan menggunakan nilai spread 0,001. Berikut adalah hasil peramalan tiga periode kedepan:

Tabel 2. Hasil Peramalan

No	Hasil Prediksi
1	3676,7
2	3438,7
3	3556,9

Peramalan ARIMA

Peramalan dengan metode ARIMA diperoleh suatu model yaitu MA(3). Metode ARIMA menghasilkan nilai prediksi untuk tiga periode kedepan masing – masing secara berurutan yaitu: 3536,573;3529,189 dan 3529,629 dengan nilai RMSE sebesar 244,86.

KESIMPULAN DAN SARAN

Metode GRNN memberikan gambaran nilai prediksi *insample* dan *outsample*. Kedua prediksi tersebut menunjukkan bahwa pola data prediksi hampir menyerupai data asli. Hasil prediksi seperti pada tabel 2.

Metode ARIMA menghasilkan model yaitu MA(3) tetapi hasil prediksi yang diperoleh dengan metode ini tidak menjelaskan adanya pengaruh variabel lain yang mungkin dapat mempengaruhi hasil prediksi. Metode ARIMA menghasilkan nilai MSE yang lebih besar dari metode GRNN sehingga hasil prediksi tidak lebih akurat dari GRNN.

Penelitian ini juga dapat dilakukan dengan melihat hubungan timbal balik antara nilai kurs dollar dan IHSG serta menambah variabel – variabel lain yang mungkin berpengaruh sehingga nantinya diperoleh suatu prediksi yang lebih akurat.

DAFTAR PUSTAKA

- Cryer, J.D. (1986). *Time Series Analysis*, PWS-Kent publishing Company, Boston.
- Hermawan, A. (2006). *Jaringan Saraf Tiruan Teori dan Aplikasi*, Andi, Yogyakarta.
- Leung, M.T., Chen, A.N., & Douck, H. (2000). Forecasting Exchange Rates Using General Regression Neural Network, *Computer and Operations Research*. (27). 1093-1110. www.elsevier.com.
- Warsito, B. (2006). Perbandingan Model FFNN dan GRNN Pada Data Nilai Tukar Yen Terhadap Rupiah. *Prosiding SPMIPA*. 127-131.