

# Pendekatan Regresi Nonparametrik dengan Fungsi Kernel untuk Indeks Harga Saham Gabungan

NUR AZIZAH KOMARA RIFAI

Program Studi Statistika, Universitas Islam Bandung, Jl. Ranggamalela No. 1 Bandung 40116  
azizah\_kr@yahoo.com

## ABSTRAK

Saham merupakan salah satu instrumen investasi yang sangat populer di kalangan investor. Salah satu indikator pergerakan harga saham di Indonesia adalah *Jakarta Composite Index* (JCI). Data JCI adalah data deret waktu tentang harga saham gabungan yang dapat dianalisis dengan metode analisis deret waktu. Namun, dengan metode ini ada asumsi yang tidak dapat dipenuhi. Dalam penelitian ini, data JCI akan dianalisis dengan metode nonparametrik yaitu regresi kernel dan penduga Nadaraya-Watson. Data harga penutupan IHSG periode Januari 2015 sampai dengan Desember 2015 diterapkan menggunakan berbagai fungsi kernel yang meminimalkan nilai validasi silang untuk mendapatkan *bandwidth* yang optimal. Hasil penelitian menunjukkan bahwa regresi kernel biweight dengan *Mean Square Error* = 9030,63 dan *bandwidth* = 108,2 adalah model terbaik untuk prediksi.

*Kata kunci: bandwidth, Jakarta Composite Index, Regresi Kernel, Penduga Nadaraya-Watson, Analisis Deret Waktu*

## ABSTRACT

Stock is one of the investment instruments that is very popular among investors. One indicator of stock price movements in Indonesia is the Jakarta Composite Index (JCI). JCI data is a time series data about joint stock prices which can be analyzed by time series analysis method. However, with this method there are assumptions that cannot be fulfilled. In this study, JCI data will be analyzed by a nonparametric method namely kernel regression with Nadaraya-Watson estimator. The weekly JCI closing price data from January 2015 to December 2015 is applied using various kernel functions that minimize the value of cross validation to get the optimal bandwidth. The results show that the biweight kernel regression with Mean Square Error = 9030,63 and bandwidth = 108,2 is the best model for predictions.

*Keywords: Bandwidth, Jakarta Composite Index, Kernel Regression, Nadaraya-Watson Estimator, Time Series Analysis.*

## 1. PENDAHULUAN

Saham adalah salah satu instrumen investasi yang sangat populer di kalangan investor. Menurut Bursa Efek Indonesia, indeks harga saham adalah indikator dari pergerakan harga saham yang dinyatakan dalam angka indeks. Angka basis indeks yang ditetapkan oleh setiap bursa efek berbeda-beda, yaitu ada yang dimulai dengan basis 100, 500 atau 1000. Saat ini, 11 jenis indeks harga saham di Bursa Efek Indonesia secara terus menerus disebarluaskan melalui media cetak maupun elektronik. Salah satu indeks harga saham tersebut adalah Indeks Harga Saham Gabungan (IHSG) atau dikenal sebagai *Jakarta Composite Index* (JCI). IHSG merupakan salah satu indikator di Bursa Efek Indonesia yang sering digunakan para investor sebagai acuan untuk melihat pergerakan harga saham ketika akan membeli atau menjual saham di pasar modal.

Data IHSG merupakan data deret waktu yang berisi informasi mengenai harga saham gabungan yang dihitung setiap hari setelah perdagangan. Di antara posisi harga, harga penutupan (*closing price*) adalah harga terpenting yang merupakan harga saham terakhir kali

pada saat transaksi ditutup. Harga penutupan (*closing price*) saham di hari itu juga akan menjadi acuan harga pembukaan di hari esok. Salah satu metode yang dapat diterapkan untuk menganalisis data harga penutupan (*closing price*) IHSG adalah analisis deret waktu. Akan tetapi, dalam memodelkan data deret waktu IHSG yang fluktuatif dengan menggunakan analisis deret waktu, seringkali ditemukan permasalahan yaitu adanya asumsi-asumsi yang tidak dapat dipenuhi. Hal tersebut akan menyebabkan analisis menjadi kurang tepat digunakan karena akan memberikan hasil yang tidak akurat.

Menurut Puspitasari (2012) selain menggunakan metode deret waktu, metode alternatif lain yaitu regresi nonparametrik dapat digunakan dalam analisis IHSG karena metode ini tidak memerlukan asumsi-asumsi khusus yang harus dipenuhi. Penelitian tersebut menggunakan model regresi nonparametrik dengan fungsi kernel box, triangle, parzen, dan normal yang dibandingkan dengan analisis deret waktu dan regresi linier. Hasil penelitian menunjukkan bahwa model pemulusan terbaik untuk data IHSG pada periode tersebut adalah model regresi kernel triangle dengan *Mean Square Error* (MSE) terkecil dan nilai *bandwidth* optimum serta penduga Nadaraya-Watson. Selain itu, Maysyaroh (2015) menggunakan metode regresi kernel gaussian dan penduga Nadaraya-Watson untuk mengetahui pengaruh kurs pada indeks harga saham *Jakarta Islamic Index* (JII) dan hasil menunjukkan bahwa kurs mempengaruhi harga indeks saham JII.

Oleh karena itu, pola sebaran data deret waktu IHSG dalam penelitian ini yang tidak diketahui sebarannya akan dianalisis menggunakan pendekatan regresi nonparametrik dengan fungsi kernel biweight, cosine, epanechnikov, gaussian, optcosine, rectangular, triangular dan penduga Nadaraya-Watson yang dibandingkan berdasarkan MSE terkecil dan nilai *bandwidth* optimum. Dari model yang didapat melalui metode tersebut akan dipilih model terbaik untuk memprediksikan nilai IHSG berikutnya.

## 2. DATA DAN METODE

### Sumber Data

Data deret waktu harga penutupan (*closing price*) IHSG pada minggu pertama Januari 2015 hingga minggu ke empat Desember 2015 digunakan dalam penelitian ini. Data tersebut adalah data sekunder yang diperoleh dari *Yahoo Finance*. *Software* yang digunakan dalam penelitian ini menggunakan *Microsoft Excel* dan *R 3.2.4*. Tahapan dalam penelitian ini meliputi (1) analisis deret waktu klasik, (2) analisis regresi nonparametrik kernel, (3) pemilihan fungsi kernel dengan penduga Nadaraya-Watson (4) pemilihan *bandwidth* optimum, dan (4) prediksi menggunakan model terbaik.

### Analisis Deret Waktu

Data deret waktu adalah rangkaian data yang berisi nilai pengamatan yang diukur dalam kurun waktu tertentu dengan interval yang sama. Analisis deret waktu merupakan metode yang mempelajari rangkaian data tersebut dengan menggunakan data historis untuk peramalan jangka pendek atau jangka panjang. Dasar pemikirannya adalah adalah pengamatan saat ini ( $Z_t$ ) bergantung pada satu atau beberapa pengamatan sebelumnya ( $Z_{t-k}$ ). Peramalan dapat digunakan dalam mencari pola dan mencocokkan data secara tepat dengan model tertentu sehingga nilai mendatang dapat diprediksi berdasarkan nilai dari peristiwa sebelumnya yang telah terjadi. Ada beberapa metode pemulusan untuk analisis deret waktu diantaranya model yang sering digunakan adalah model *autoregressive* (AR), *moving average* (MA), *autoregressive moving average* (ARMA), dan *autoregressive integrated moving average* (ARIMA) (Puspitasari, 2012).

- a. Model *autoregressive* orde  $p$  atau AR( $p$ ) yaitu:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (1)$$

- b. Model *moving average* orde  $q$  atau MA( $q$ ) yaitu:

$$Z_i = \varepsilon_i + \theta_1 \varepsilon_{i-1} + \theta_2 \varepsilon_{i-2} + \dots + \theta_q \varepsilon_{i-q} \quad (2)$$

c. Model *autoregressive* orde  $p$  dan model *moving average* orde  $q$  atau ARMA( $p, q$ ) yaitu:

$$Z_i = \phi_1 Z_{i-1} + \phi_2 Z_{i-2} + \dots + \phi_p Z_{i-p} + \varepsilon_i + \theta_1 \varepsilon_{i-1} + \theta_2 \varepsilon_{i-2} + \dots + \theta_q \varepsilon_{i-q} \quad (3)$$

d. Model *autoregressive* orde  $p$ , *integrated* orde  $d$ , dan *moving average* orde  $q$  atau ARIMA( $p, d, q$ ) yaitu:

$$\phi_p(B)(1-B)^d Z_i = \theta_q(B) \varepsilon_i \quad (4)$$

### Regresi Nonparametrik

Analisis regresi merupakan analisis yang mempelajari hubungan fungsional antara satu atau beberapa peubah penjelas dengan satu peubah respon. Pendekatan yang digunakan untuk menduga fungsi tersebut bisa dilakukan dengan parametrik atau nonparametrik. Pendekatan yang paling banyak digunakan adalah pendekatan parametrik seperti model regresi linier. Menurut Eubank (1999), pendekatan regresi parametrik digunakan apabila bentuk fungsi, kurva diketahui atau berdasarkan pengalaman dan informasi sebelumnya, sedangkan pendekatan regresi nonparametrik digunakan berdasarkan pendekatan yang tidak terikat dengan asumsi bentuk fungsi atau kurva tertentu sehingga memiliki fleksibilitas yang lebih besar untuk menyesuaikan dengan data aslinya. Bentuk umum model regresi nonparametrik adalah (Simonoff, 1996):

$$y_i = m(x_i) + \varepsilon_i; \quad i = 1, 2, 3, \dots, n \quad (5)$$

dengan  $\varepsilon_i$  diasumsikan sebagai galat yang bebas stokastik identik dengan rata-rata 0 dan ragam  $\sigma^2$ , dan  $m(x_i)$  adalah fungsi regresi yang tak diketahui dan yang akan diduga.

Model nonparametrik untuk data deret waktu ( $Z_i, i \geq 1$ ) adalah hasil pengamatan dan dalam memprediksi  $Z_{n+1}$  dengan  $m(x) = E(Z_{n+1} | Z_n = x)$ . Satu langkah untuk memprediksi masalah deret waktu berdimensi satu dapat digambarkan ke model pertama dengan menentukan deret waktu stasioner  $\{Z_i, i \geq 1\}$ . Nilai lag  $Z_{i-1}$  sebagai  $X_i$  dan nilai  $Z_i$  sebagai  $Y_i$ . Kemudian, pendugaan  $Z_{n+1}$  dari  $\{Z_i\}_{i=2}^n$  dapat dipandang sebagai masalah regresi pemulusan untuk  $\{(X_i, Y_i)\}_{i=2}^n = \{(Z_{i-1}, Z_i)\}_{i=2}^n$ . Permasalahan prediksi untuk deret waktu  $\{Z_i\}$  adalah sama seperti dugaan  $m(x) = E(Y | X = x)$  untuk dua dimensi deret waktu  $\{(X_i, Y_i)\}_{i=2}^n$ .

#### 1. Fungsi Kernel

Dalam pendekatan metode nonparametrik, metode pemulus kernel memiliki beberapa macam fungsi yang digunakan untuk menduga fungsi regresi  $m(x_i)$ . Fungsi kernel atau  $K(u)$  adalah suatu fungsi yang simetris, kontinu, terbatas, dan  $\int_{-\infty}^{\infty} K(u) du = 1$ . Berikut macam-macam fungsi kernel yang terdapat pada *software R 3.2.4*.

**Tabel 1.** Fungsi Kernel

Jenis Kernel	Bentuk Fungsi
Biweight	$K_B(u) = \begin{cases} \frac{15}{16} \left(1 - \frac{1}{5} u^2\right); & \text{untuk }  u  \leq 1 \\ 0 & ; \text{ untuk } u \text{ lainnya} \end{cases}$

Jenis Kernel	Bentuk Fungsi
Cosine	$K_C(u) = \begin{cases} \frac{\pi}{4} \cos\left(\frac{\pi}{2}u^2\right); & \text{untuk }  u  \leq 1 \\ 0 & ; \text{ untuk } u \text{ lainnya} \end{cases}$
Epanechnikov	$K_E(u) = \begin{cases} \frac{3}{4\sqrt{5}} \left(1 - \frac{1}{5}u^2\right); & \text{untuk }  u  \leq \sqrt{5} \\ 0 & ; \text{ untuk } u \text{ lainnya} \end{cases}$
Gaussian	$K_G(u) = \begin{cases} \frac{1}{\sqrt{2\pi}} e^{-u^2/2}; & \text{untuk } -\infty < u < \infty \\ 0 & ; \text{ untuk } u \text{ lainnya} \end{cases}$
Optcosine	$K_O(u) = \begin{cases} \sqrt{1 - \frac{8}{\pi^2} \left(\frac{\pi^2}{16}\right)}; & \text{untuk }  u  \leq 1 \\ 0 & ; \text{ untuk } u \text{ lainnya} \end{cases}$
Rectangular	$K_R(u) = \begin{cases} \frac{1}{2}; & \text{untuk }  u  \leq 1 \\ 0; & \text{untuk } u \text{ lainnya} \end{cases}$
Triangular	$K_T(u) = \begin{cases} 1 -  u ; & \text{untuk }  u  \leq 1 \\ 0 & ; \text{ untuk } u \text{ lainnya} \end{cases}$

## 2. Regresi Kernel Nadaraya-Watson

Model regresi nonparametrik kernel pada persamaan (5), dengan  $m(x)$  diduga dengan penduga Nadaraya-Watson. Pada penduga Nadaraya-Watson diasumsikan bahwa peubah penjelas dan peubah respon keduanya adalah peubah acak. Misal,  $f(x)$  adalah fungsi peluang dari peubah acak  $X$ ,  $f(y)$  adalah fungsi peluang dari peubah acak  $Y$ , dan  $f(x,y)$  adalah fungsi peluang bersama untuk dari acak  $(X, Y)$ , maka

$$m(x) = \frac{1}{f_X(x)} \int_{-\infty}^{\infty} y f(x,y) dy \quad (6)$$

Dengan mengadopsi penduga fungsi kepadatan kernel, metode yang paling sederhana dari beberapa metode pendugaan  $f(x,y)$  dan  $f_X(x)$  diantaranya adalah

$$\hat{f}(x,y) = \frac{1}{nh_x h_y} \sum_{i=1}^n K_x\left(\frac{x-X_i}{h_x}\right) K_y\left(\frac{y-Y_i}{h_y}\right) \quad (7)$$

$$\hat{f}_X(x) = \frac{1}{nh_x} \sum_{i=1}^n K_x\left(\frac{x-X_i}{h_x}\right) \quad (8)$$

dimana  $K_x\left(\frac{x-X_i}{h_x}\right)$  dan  $K_y\left(\frac{y-Y_i}{h_y}\right)$  adalah suatu fungsi kernel,  $h_x$  dan  $h_y$  adalah bilangan positif yang dikenal sebagai *bandwidth*. Kemudian, karena

$$\hat{m}(x) = \frac{1}{\hat{f}_x(x)} \int_{-\infty}^{\infty} y \hat{f}(x, y) dy \quad (9)$$

maka diperoleh penduga Nadaraya-Watson sebagai berikut (Takezawa, 2006)

$$\hat{m}(x) = \frac{\sum_{i=1}^n K\left(\frac{x-X_i}{h_x}\right) Y_i}{\sum_{i=1}^n K_i\left(\frac{x-X_i}{h}\right)} \quad (10)$$

$$\hat{m}(x) = \sum_{i=1}^n W_i(x) Y_i \quad (11)$$

$$\text{dimana } W_i(x) = \frac{K\left(\frac{x-X_i}{h_x}\right)}{\sum_{i=1}^n K\left(\frac{x-X_i}{h}\right)} \text{ dan } \sum W_i(x) = \frac{\sum_{i=1}^n K\left(\frac{x-X_i}{h}\right)}{\sum_{i=1}^n K\left(\frac{x-X_i}{h}\right)} = 1.$$

### 3. Pemilihan *Bandwidth* Optimum

Perbedaan penggunaan fungsi kernel dalam menduga fungsi regresi  $m(x_i)$  dibanding penduga lainnya hanya terletak pada penggunaan metode *bandwidth* yang digunakan. Fungsi dugaan akan *undersmooth* dan memiliki ragam yang besar jika  $h$  mendekati nol. Sebaliknya, fungsi dugaan akan *oversmooth* dan bias akan tinggi jika  $h$  besar. Analisis data dengan regresi kernel akan memungkinkan penggunaan beberapa *bandwidth* ( $h$ ) optimum dan memilih penduga yang akan digunakan berdasarkan kriteria nilai *Mean Square Error* (MSE) yaitu sebagai berikut (Ogden, 1997):

$$\text{MSE}(\hat{m}) = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{m}(x_i))^2 \quad (12)$$

Akan tetapi, penggunaan metode tersebut bukan merupakan metode yang tepat untuk mengevaluasi model. Semakin kecil nilai MSE maka *bandwidth* yang dihasilkan juga akan semakin kecil, sehingga akan memberikan pemulusan yang *undersmooth*. Salah satu metode pendekatan selain MSE yang bisa dijadikan kriteria untuk menemukan sebuah dugaan yang tidak bias pada regresi nonparametrik dalam memilih *bandwidth* optimum adalah *cross validation* (CV). Metode CV adalah metode penggunaan data untuk menunjukkan apa yang harus dilakukan jika pengulangan amatan tersedia (Härdle, 1990). Langkah pertama, satu pengamatan ke- $j$  dikeluarkan kemudian  $(n-1)$  data sisanya digunakan untuk mendapatkan penghalusan pada

$$\hat{m}_{h,j}(x_j) = n^{-1} \sum_{i \neq j} W_{hi}(x_j) Y_i \quad (13)$$

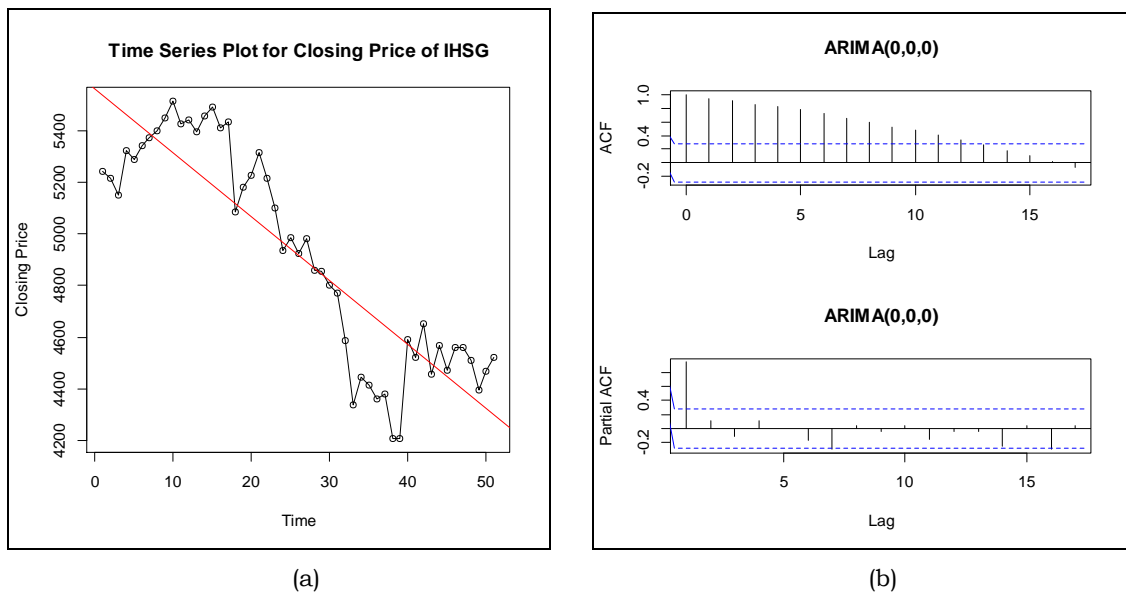
Ulangi langkah pertama untuk  $j = 1, 2, \dots, n$ , maka akan didapatkan fungsi sebagai berikut.

$$\text{CV}(h) = n^{-1} \sum_{j=1}^n [Y_j - \hat{m}_{h,j}(x_j)]^2 \quad (14)$$

### 3. HASIL DAN PEMBAHASAN

#### Analisis Deret Waktu

Dari data IHSB diperoleh Gambar 1. (a) yang menunjukkan bahwa data tidak stasioner. Dari pengujian stationeritas dengan menggunakan *Augmented Dickey-Fuller* juga diperoleh  $p\text{-value} = 0,7056$ , artinya bahwa data IHSB tidak stasioner.

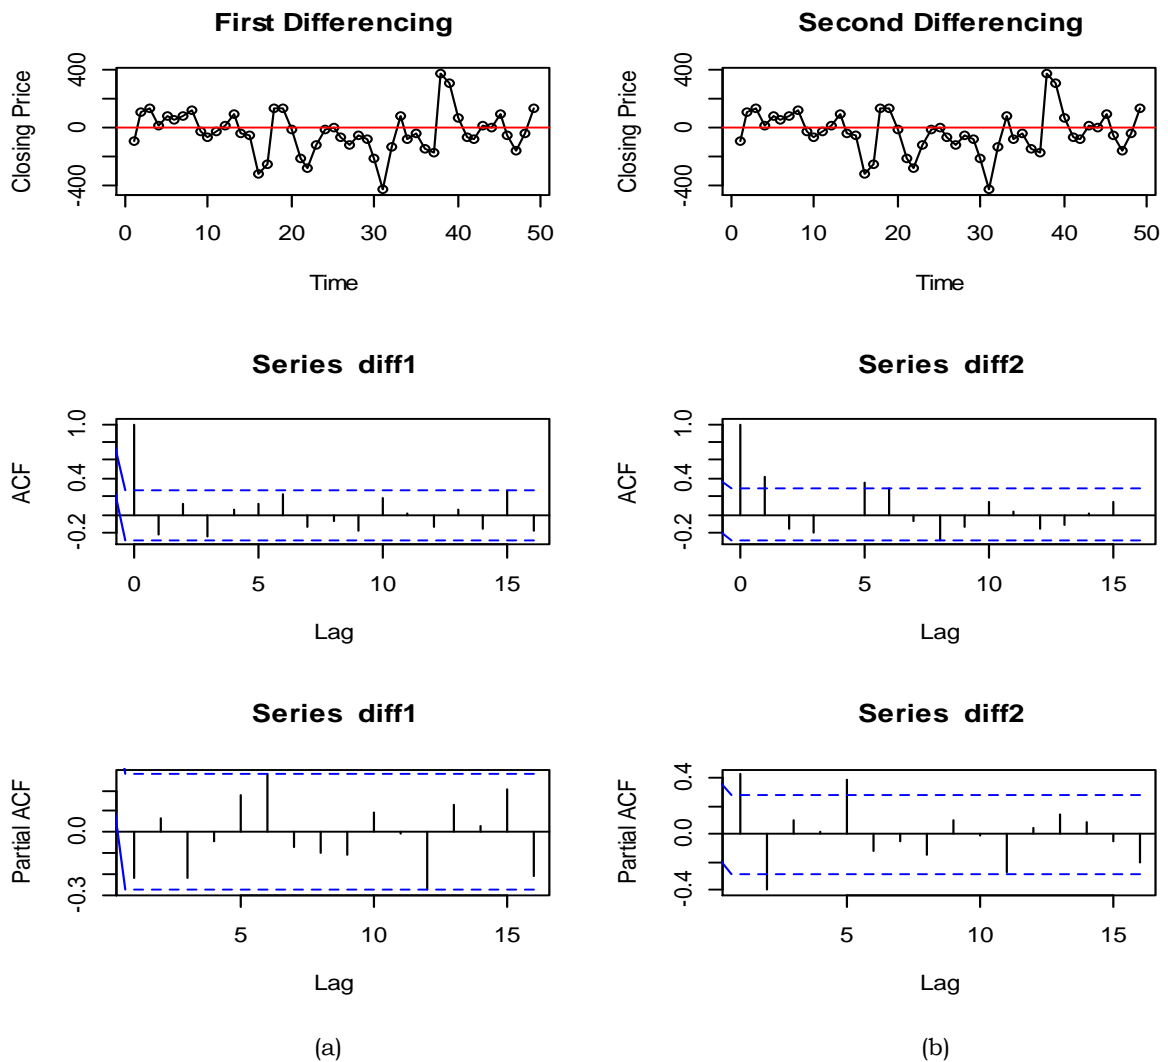


**Gambar 1.** (a) Plot stasioneritas, (b) ACF dan PACF data IHSB

Pada Gambar 1. (b) *Auocorrelation Function* (ACF) menunjukkan adanya tren linier yang mengalami penurunan autokorelasi secara perlahan-lahan. ACF sangat signifikan pada beberapa lag, akan tetapi autokorelasi pada lag 2 ke atas hanyalah pengaruh dari autokorelasi pada lag 1. Hal ini ditegaskan oleh plot *Partial Auocorrelation Function* (PACF). Perhatikan bahwa plot PACF memiliki lonjakan yang signifikan pada lag 1 dan tidak ada lonjakan yang signifikan pada lag lainnya. Hal ini berarti bahwa semua korelasi tingkat tinggi secara efektif dijelaskan oleh autokorelasi lag 1 atau ketika tidak adanya *differencing* maka model AR(1) dapat digunakan. Akan tetapi, dengan adanya ketidakstasioneran pada data maka ketidakstasioneran maka perlu dihilangkan dengan metode *differencing*.

Setelah dilakukan *first differencing*, pada Gambar 2. (a) terlihat bahwa data sudah stasioner. Pengujian stationeritas untuk *first differencing* dengan *Augmented Dickey-Fuller* diperoleh  $p\text{-value} = 0,02064$ , artinya bahwa data IHSB stasioner. Plot ACF menunjukkan sudah tidak ada trend linear, namun tidak banyak lag yang mendekati nol sesudah lag kedua atau ketiga. Selain itu, pada PACF *first differencing* tidak ada lag yang menyentuh batas signifikansi, Oleh karena itu perlu dilakukan *second differencing*.

Pada *second differencing* seperti pada Gambar 2. (b) terlihat bahwa kestasioneran data tidak berbeda jauh dengan *first differencing*. Akan tetapi, pengujian stationeritas untuk *second differencing* dengan *Augmented Dickey-Fuller* diperoleh  $p\text{-value} = 0,1669$ , artinya bahwa data IHSB tidak stasioner. Autokorelasi parsial ada yang mendekati nol tetapi tandanya berubah-ubah dan terlihat terdapat satu nilai positif yang besar pada lag 1 atau model MA(1). Dua koefisien parsial positif dan negatif yang signifikan memberikan petunjuk adanya pola autoregresif orde kedua di dalam data atau model AR(2) sehingga model untuk *second differencing* yang didapatkan adalah ARIMA (0,2,1), ARIMA (1,2,0), ARIMA (2,2,0), ARIMA (1,2,1), ARIMA (2,2,1).



**Gambar 2.** (a) Plot stasioneritas, ACF dan PACF data IHSG dengan first differencing  
 (b) Plot stasioneritas, ACF dan PACF data IHSG dengan second differencing

**Tabel 2.** Hasil analisis deret waktu dengan model ARIMA

Model	Signifikansi Parameter	AIC	Normalitas Residual	Independensi Residual
ARIMA(0,2,1)	MA(1)	614,52	√	×
ARIMA(1,2,0)	AR(1)	628,87	×	×
ARIMA(2,2,0)	AR(1)	629,03	√	×
ARIMA(1,2,1)	MA(1)	614,51	√	×
ARIMA(2,2,1)	MA(1)	616,15	×	×

Dari uji sinifikansi parameter pada Tabel 2, model ARIMA(0,2,1) dan ARIMA(1,2,0) signifikan. Dari uji normalitas residual hanya model ARIMA(0,2,1), ARIMA(2,2,0), dan ARIMA(1,2,1) yang signifikan memiliki sisaan yang berdistribusi normal. Akan tetapi, dari uji independensi

residual, semua model memiliki korelasi residual antar lag. Oleh karena itu, analisis deret waktu tidak tepat digunakan untuk data harga penutupan (*closing price*) IHSG mingguan di tahun 2015 karena banyak asumsi-asumsi seperti stasioneritas dan tidak adanya korelasi residual antara lag yang tidak dapat dipenuhi.

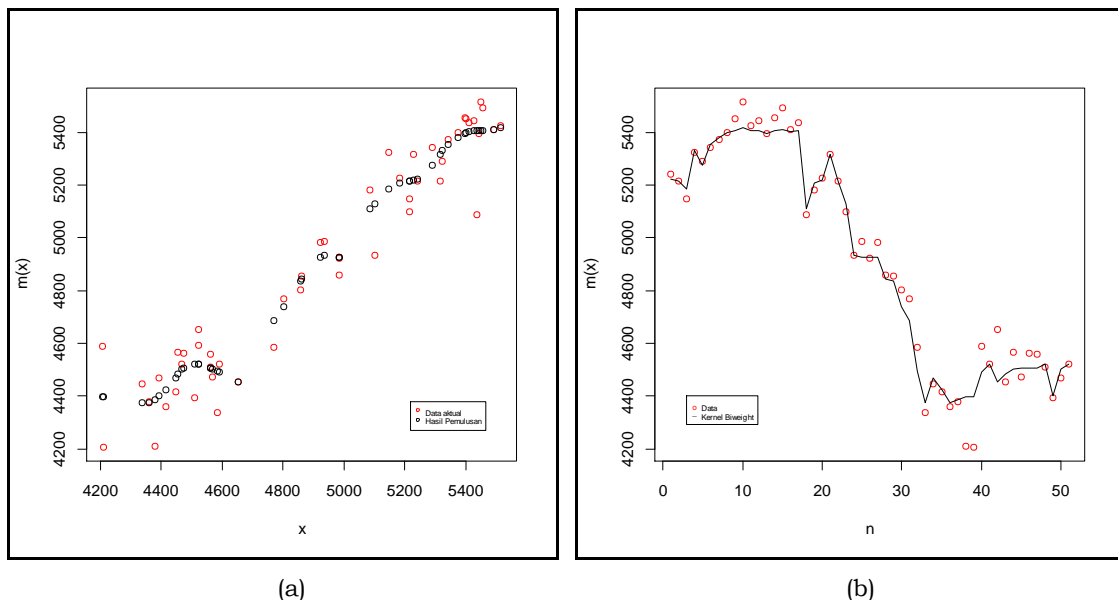
### Regresi Nonparametrik Kernel

Analisis regresi nonparametrik dengan fungsi kernel dilakukan dengan cara meminimalkan *cross validation* untuk mendapatkan *bandwidth* optimum, selanjutnya mencari nilai MSE. Berikut ini hasil dari regresi nonparametrik kernel biweight, cosine, epanechnikov, gaussian, optcosine, rectangular, dan triangular.

**Tabel 3.** Hasil analisis regresi kernel

Regresi Nonparametrik Kernel	Pembanding		
	CV <sub>min</sub>	h <sub>opt</sub>	MSE
Biweight	17930,04	108,20	9030,63
Cosine	13408,21	310,07	11377,26
Epanechnikov	13420,45	137,07	11458,04
Gaussian	13392,81	143,12	11156,27
Optcosine	13391,65	152,67	10565,00
Rectangular	13343,80	267,26	11869,24
Triangular	13386,29	349,72	11134,25

Model terbaik yang didapat dengan membandingkan nilai MSE dari hasil analisis regresi nonparametrik kernel pada Tabel 3 adalah analisis dengan menggunakan fungsi biweight dengan nilai MSE = 9030,63. Sehingga model dengan fungsi biweight digunakan dalam prediksi regresi kernel. Grafik hasil pemulusan kernel biweight adalah sebagai berikut.



**Gambar 3.** (a) Grafik pemulusan kernel biweight terhadap X dengan  $h = 108,2$   
 (b) Grafik pemulusan kernel biweight terhadap n dengan  $h = 108,2$



## Hasil Prediksi

Model regresi terbaik pada kasus ini yaitu model regresi kernel biweight. Model ini digunakan untuk memprediksi nilai Y yang akan datang. Pada penelitian ini, nilai Y di minggu terakhir sudah diketahui dan selanjutnya digunakan untuk membandingkan nilai Y aktual dengan Y prediksi seperti pada Tabel 4 berikut.

**Tabel 4.** Hasil prediksi nilai penutupan (closing price) IHSG

Data ke-	Y	Y Prediksi
52	4593,01	4488,98
53	4546,29	4513,26
54	4523,98	4521,03
55	4456,74	4486,25
56	4615,16	4473,54
57	4798,95	4734,52
58	4714,39	4550,15
59	4697,56	4495,57
60	4733,15	4613,48
61	4850,88	4824,59

## 4. KESIMPULAN

Hasil perbandingan nilai MSE dari data *closing price* IHSG dari berbagai macam fungsi kernel diperoleh nilai MSE terkecil yaitu pada model regresi dengan fungsi kernel biweight dengan *bandwidth* optimum  $h = 108,2$  dan nilai MSE = 9030,63. Dengan pemulusan menggunakan regresi kernel dan penduga Nadaraya-Watson ini diperoleh nilai prediksi harga penutupan (*closing price*) IHSG untuk sepuluh minggu ke depan. Sehingga metode regresi nonparametrik dengan fungsi kernel biweight dapat digunakan sebagai alternatif lain untuk menyelesaikan permasalahan yang terjadi pada analisis deret waktu untuk data harga penutupan (*closing price*) IHSG pada minggu pertama Januari 2015 hingga minggu ke empat Desember 2015.

## DAFTAR PUSTAKA

- Eubank, R.L. (1999). "Nonparametric Regression and Spline Smoothing", Second Edition, New York: Marcel Dekker, Inc. Vol.157.
- Härdle, W. (1990). "Applied Nonparametric Regression", New York: Cambridge University Press.
- Maysyaroh, N. (2015). Regresi Nonparametrik Kernel Nadaraya-Watson dalam Data Time Series (Studi Kasus: Penutupan Indeks Harga Saham Harian Jakarta Islamic Index (JII) Periode 3 Maret 2014 – 30 maret 2015). Yogyakarta: Program Studi Matematika Fakultas Sains dan Teknologi UIN Sunan Kalijaga.
- Ogden, R.T. (1997). "Essential Wavelets for Statistical Applications and Data Analysis", Boston: Birkhäuser Basel.
- Puspitasari, I., Suparti, Wilandari Y. (2012). Analisis Indeks Harga Saham Gabungan (IHSG) dengan Menggunakan Model Regresi Kernel. *Jurnal Gaussian*, Vol. 1, pp. 93-102.
- Simonoff, J.S. (1996). "Smoothing Methods in Statistics", New York: Springer-Verlag.
- Takezawa, K. (2006). "Introduction to Nonparametric Regression", New Jersey: John Wiley & Sons, Inc.
- Yahoo Finance (<http://finance.yahoo.com/q/hp?s=%5EJKSE&a=00&b=1&c=2015&d=11&e=31&f=2015&g=w>) diakses pada 28 Maret 2016.