

ANALISIS *SUPPORT VECTOR REGRESSION* (SVR) DALAM MEMPREDIKSI KURS RUPIAH TERHADAP DOLLAR AMERIKA SERIKAT

Risky Amanda¹, Hasbi Yasin², Alan Prahutama³

¹Mahasiswa Jurusan Statistika FSM UNDIP

^{2,3}Staff Pengajar Jurusan Statistika FSM UNDIP

ABSTRACT

In economy, the global markets have an important role as a forum for international transactions between countries in selling or purchasing goods or services on an international scale. Money as legal tender in the trading activities, but the problem is the difference between the state of the currency, the exchange rate will be established. Exchange rate is the value of a country's currency is expressed in another country's currency value. Fluctuations in foreign exchange rates greatly affect the Indonesian economy, so the determination of the exchange rate should be beneficial to a country can run the economy well. To predict the exchange rate of the Rupiah against the United States dollar in this study used methods of Support Vector Regression (SVR) is a technique to predict the output in the form of continuous data. SVR aims to find a hyperplane (line separator) in the form of the best regression function is used to predict the exchange rate against the United States dollar with linear kernel and polynomial functions. Criteria used in measuring the goodness of the model is the MAPE (Mean Absolute Percentage Error) and R² (coefficient of determination). The results of this study indicate that both the kernel function gives very good accuracy in the prediction results of the exchange rate with R² of 99.99% with MAPE 0.6131% in the kernel linear and R² result of 99.99% with MAPE 0.6135% in the kernel polynomial.

Keyword : Exchange rate, Support Vector Regression (SVR), Hyperplane, Linear Kernel, Polynomial Kernel, ϵ -insensitive, Accuracy

1. PENDAHULUAN

Sebagai negara berkembang, fluktuasi kurs mata uang asing sangat berpengaruh terhadap perekonomian Indonesia, sehingga penentuan kurs valuta asing harus menguntungkan agar suatu negara dapat menjalankan perekonomiannya dengan baik. Pergerakan kurs di Indonesia yang fluktuatif mengakibatkan pihak-pihak yang berkepentingan harus menyiapkan langkah strategis agar dapat mengatasi masalah yang timbul akibat fluktuasi kurs dan tidak mengalami kerugian yang besar. Prediksi besar kurs mata uang dilakukan agar mengetahui besar nilai tukar mata uang yang terjadi diwaktu mendatang agar pemerintah dapat mengambil kebijakan yang tepat.

Support Vector Machine (SVM) adalah metode berbasis kecerdasan buatan yang sangat populer. SVM merupakan metode yang memiliki keunggulan dalam optimasi sistem pengenalan pola dengan kemampuan generalisasi yang baik. SVM juga dapat digunakan untuk meramalkan suatu nilai, seperti yang telah diperkenalkan

oleh Vapnik akhir tahun 1960 (Santosa, 2007). SVM berusaha menemukan *hyperplane* (garis pemisah) terbaik antar kelas. Metode SVM dapat digunakan dalam kasus regresi dan data nonlinier dengan jumlah input data yang besar, dalam kasus ini metode SVM yang digunakan adalah *Support Vector Regression* (SVR) dengan output berupa data kontinu. Menggunakan konsep *loss function* SVR dapat digunakan untuk kasus regresi, beberapa jenis *loss function* adalah ε -insensitive, *quadratic*, *Huber* dan *Lapace*. SVR digunakan untuk meramalkan nilai tukar kurs Rupiah terhadap Dollar Amerika Serikat dengan kriteria keakuratan yang digunakan adalah MAPE (*Mean Absolute Percentage Error*) dan R^2 (Koefisien Determinasi). Penelitian sebelumnya yang telah dilakukan menggunakan metode SVR adalah “*Sistem Prediksi Status Gizi Balita Dengan Menggunakan Support Vector Regression*” oleh Hidayat (2013) dan “*Prediksi Awal Musim Hujan Menggunakan Data Southern Oscillation Index Dengan Metode Support Vector Regression*” oleh Larasati (2012).

2. TINJAUAN PUSTAKA

2.1 Pengertian Kurs

Menurut Kamus Besar Bahasa Indonesia kurs adalah nilai mata uang suatu negara yang dinyatakan dengan nilai mata uang negara lain. Mankiw (2007) menyebutkan Kurs (*exchange rate*) antara dua negara adalah tingkat harga yang disepakati penduduk kedua negara untuk saling melakukan perdagangan. Mankiw (2007) juga menyebutkan kenaikan kurs disebut dengan apresiasi, sementara penurunan kurs disebut depresiasi. Ketika kurs domestik menurun, daya belinya pada mata uang luar negeri berkurang begitu juga sebaliknya. Apresiasi disebut juga dengan penguatan (*strengthening*) mata uang, dan depresiasi disebut juga dengan pelemahan (*weakening*).

2.2 Support vector Regression


Support Vector Regression (SVR) merupakan pengembangan SVM untuk kasus regresi. Tujuan dari SVR adalah untuk menemukan sebuah fungsi $f(x)$ sebagai suatu *hyperplane* (garis pemisah) berupa fungsi regresi yang mana sesuai dengan semua input data dengan sebuah *error* ε dan membuat ε setipis mungkin (Scholkopt and Smola, 2002).

Abe (2005) menyatakan tujuan dari SVR ini adalah untuk memetakan *vector* input ke dalam dimensi yang lebih tinggi. Misalkan sebuah fungsi berikut adalah garis regresi sebagai *optimal hyperplane* :

$$f(x) = \mathbf{w}^T \varphi(x) + b$$

Pada regresi terdapat residual misalkan residual (r) didefinisikan dengan mengurangkan output skalar y terhadap estimasi $f(x)$ yaitu $r = y - f(x)$ dengan :

$$E(r) = \begin{cases} 0 & \text{untuk } |r| \leq \varepsilon \\ |r| - \varepsilon & \text{untuk yang lain} \end{cases}$$



Gambar 2. *Insensitive zone* (a) *original input space*, dan (b) *feature space*

$D(x, y) = \pm \varepsilon$ adalah jarak terjauh *support vector* dari *hyperplane*, kemudian disebut margin. Memaksimalkan margin akan meningkatkan probabilitas data ke dalam radius $\pm \varepsilon$. Jarak dari *hyperplane* $D(x, y) = 0$ ke data (x, y) adalah $|D(x, y)| / \|\mathbf{w}^*\|$, dimana :

$$\mathbf{w}^* = (1 - \mathbf{w}^T)^T$$

Diasumsikan bahwa jarak maksimum data terhadap *hyperplane* adalah δ , maka estimasi yang ideal akan terpenuhi dengan :

$$\begin{aligned} \frac{|D(x, y)|}{\|\mathbf{w}^*\|} &\leq \delta \\ |D(x, y)| &\leq \delta \|\mathbf{w}^*\| \\ \delta \|\mathbf{w}^*\| &= \varepsilon \end{aligned}$$

Oleh karena itu untuk memaksimalkan margin δ , diperlukan $\|\mathbf{w}^*\|$ yang minimum. Optimasi penyelesaian masalah dengan bentuk *Quadratic Programming* :


$$\min \frac{1}{2} \|\mathbf{w}\|^2$$

dengan syarat

$$\begin{aligned} y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - b &\leq \varepsilon \text{ untuk } i = 1, \dots, l \\ \mathbf{w}^T \varphi(\mathbf{x}_i) - y_i + b &\leq \varepsilon \text{ untuk } i = 1, \dots, l \end{aligned}$$

Faktor $\|\mathbf{w}\|^2$ dinamakan *regulasi*. Meminimalkan $\|\mathbf{w}\|^2$ akan membuat suatu fungsi setipis (*flat*) mungkin, sehingga bisa mengontrol kapasitas fungsi (*function capacity*).

Diasumsikan bahwa semua titik ada dalam rentang $f(\mathbf{x}) \pm \varepsilon$ (*feasible*), dalam hal ketidaklayakan (*infesibility*), dimana ada beberapa titik yang mungkin keluar dari rentang $f(\mathbf{x}) \pm \varepsilon$ maka ditambahkan variabel *slack* ξ dan ξ^* untuk mengatasi masalah pembatasan yang tidak layak (*infeasible constraints*) dalam problem optimasi (Santosa, 2007).



Gambar 2. (a) SVR output, dan (b) ε -insensitive loss function

Gambar 2 menjelaskan bahwa semua titik diluar margin akan dikenai pinalti. Selanjutnya problem optimisasi di atas bisa diformulasikan sebagai berikut :

$$\min \frac{1}{2} \| \mathbf{w} \|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*)$$

Dengan syarat :

$$\begin{aligned} y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - b - \xi_i &\leq \varepsilon, & i = 1, \dots, l \\ \mathbf{w}^T \varphi(\mathbf{x}_i) - y_i + b - \xi_i^* &\leq \varepsilon, & i = 1, \dots, l \\ \xi_i, \xi_i^* &\geq 0 \end{aligned}$$

Loss Function adalah fungsi yang menunjukkan hubungan antara *error* dengan bagaimana *error* ini dikenai pinalti. Perbedaan *loss function* akan menghasilkan formula SVR yang berbeda (Santosa,2007).

Loss function yang paling sederhana adalah ε -insensitive loss function sebagai sebuah pendekatan *Huber's loss function* yang memungkinkan serangkaian *support vector* akan diperoleh (Gunn,1998). Formulasi ε -insensitive loss function adalah sebagai berikut :

$$L_\varepsilon(y) = \begin{cases} 0, & \text{untuk } |f(\mathbf{x}) - y| < \varepsilon \\ |f(\mathbf{x}) - y| - \varepsilon, & \text{untuk yang lain} \end{cases}$$

Dengan konstanta $C > 0$ menentukan tawar menawar (*trade off*) antara ketipisan fungsi (*flatness of function*) $f(\mathbf{x})$ dan batas atas deviasi lebih besar dari ε masih ditoleransi. Semua deviasi lebih besar dari ε akan dikenai pinalti sebesar C .

Solusi optimisasi dapat diselesaikan dengan fungsi *Lagrange* berikut :

$$\begin{aligned} Q(\mathbf{w}, b, \xi, \xi^*, \alpha, \alpha^*, \eta, \eta^*) &= L \\ &= \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) - \sum_{i=1}^l \alpha_i (\varepsilon + \xi_i - y_i + \\ &\quad \mathbf{w}^T \varphi(\mathbf{x}_i) + b) - \sum_{i=1}^l \alpha_i^* (\varepsilon + \xi_i^* + y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - b) - \\ &\quad \sum_{i=1}^l (\eta_i \xi_i + \eta_i^* \xi_i^*) \end{aligned}$$

L dinamakan *Lagrangian*, $\eta_i, \eta_i^*, \alpha_i, \alpha_i^*$ adalah *Lagrange Multiplier*. Untuk mendapatkan solusi yang optimal, maka dilakukan turunan parsial dari Q terhadap $\mathbf{w}, b, \xi, \xi^*$. Dari Persamaan diatas \mathbf{w} dapat ditulis dengan :

$$\mathbf{w} = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \varphi(\mathbf{x}_i)$$

maka *optimal hyperplane* ditulis :

$$f(\mathbf{x}) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \varphi^T(\mathbf{x}_i) \varphi(\mathbf{x}_i) + b$$

misalkan $\beta = \alpha_i - \alpha_i^*$

maka $f(\mathbf{x}) = \sum_{i=1}^l \beta \varphi^T(\mathbf{x}_i) \varphi(\mathbf{x}_i) + b$

Optimasi permasalahan dual adalah :

$$Q(\alpha, \alpha^*) = -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \varphi^T(\mathbf{x}_i) \varphi(\mathbf{x}_j) - \varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*)$$

Solusi optimal untuk b dengan menggunakan KKT (*Karush Kuhn Tucker*) :

$$b = y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) - \varepsilon \text{ untuk } 0 < \alpha_i < C$$

$$b = y_i - \mathbf{w}^T \varphi(\mathbf{x}_i) + \varepsilon \text{ untuk } 0 < \alpha_i^* < C$$

2.3 Fungsi Kernel

Menurut Santosa (2007) banyak teknik data mining atau *machine learning* yang dikembangkan dengan asumsi kelinieran, sehingga algoritma yang dihasilkan terbatas untuk kasus-kasus yang linier. Dengan metode kernel suatu data x di *input space* dipetakan ke *feature space* dengan dimensi yang lebih tinggi melalui φ .

$$\varphi: x \rightarrow \varphi(x)$$

Nilai $K(\mathbf{x}_i, \mathbf{x}_j)$ merupakan fungsi kernel yang menunjukkan pemetaan linier pada *feature space*. Perlu dijelaskan disini bahwa nilai $K(\mathbf{x}_i, \mathbf{x}_j)$ tidak selalu bisa diekspresikan secara eksplisit sebagai kombinasi antara α , y dan $\varphi(\mathbf{x})$, karena dalam banyak kasus $\varphi(\mathbf{x})$ tidak diketahui atau sulit dihitung.

Fungsi kernel yang digunakan dalam penelitian ini adalah :

1. Kernel *Linier*

$$\varphi(\mathbf{x}) = K(\mathbf{x}, \mathbf{x}') = \mathbf{x}^T \mathbf{x}$$

2. Kernel *Polynomial*

$$\varphi(\mathbf{x}) = K(\mathbf{x}, \mathbf{x}') = \left((\mathbf{x}^T \mathbf{x}) + 1 \right)^d$$

x dan x' adalah pasangan dua data training. Parameter $d > 0$ merupakan konstanta. Fungsi kernel mana yang harus digunakan untuk substitusi *dot product* di *feature space* sangat tergantung pada data karena fungsi kernel ini akan menentukan fitur baru di mana fungsi pemisah akan dicari.

3. METODOLOGI PENELITIAN

3.1 Data dan variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data kurs jual rupiah terhadap Dollar Amerika Serikat periode 2 Januari 2012 sampai dengan 31 Desember 2013. Variabel yang digunakan dalam penelitian ini adalah kurs jual Rupiah terhadap Dollar Amerika Serikat. Data tersebut berupa data historis kemudian berlandaskan rumus *time series* data tersebut dimodifikasi menjadi data ke-1,...,n-1 sebagai variabel prediktor (x) dan data ke-2,...,n sebagai variabel respon (y).

3.2 Langkah-langkah Analisis

Langkah – langkah yang dilakukan pada penelitian ini adalah sebagai berikut :

1. Identifikasi permasalahan, yaitu dalam penelitian ini adalah prediksi kurs jual harian Rupiah terhadap Dollar Amerika Serikat.

2. Melakukan studi literatur yang meliputi tinjauan statistik dan tinjauan non statistik. Tinjauan statistik menjelaskan tentang konsep statistika khususnya prediksi menggunakan *Support Vector Regression* (SVR). Tinjauan non-statistik menjelaskan tentang teori kurs.
3. Menentukan variabel penelitian, yaitu kurs Rupiah terhadap Dollar Amerika.
4. Mengumpulkan data kurs Jual harian Rupiah terhadap Dollar Amerika Serikat periode 2 Januari 2012 sampai dengan 31 Desember 2013.
5. Melakukan analisis SVR untuk menghasilkan pemodelan menggunakan software Ms. Excel, SPSS dan Matlab R2009a.
Melakukan analisis data yang terdiri :
 - a. Analisis Deskriptif
 - b. Membagi data menjadi data *training* dan data *testing*.
 - c. Melakukan analisis SVR dengan fungsi ϵ -insensitive *Loss Function*, *Lagrange Multiplier* dan Fungsi *Kernel Linier* dan *Kernel Polynomial*.
 - d. Melakukan prediksi menggunakan model terbaik yang dihasilkan pada analisis SVR.

4. PEMBAHASAN

4.1 Analisis Deskriptif Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data harian kurs jual Rupiah terhadap Dollar Amerika Serikat periode 2 Januari tahun 2012 sampai dengan 31 Desember tahun 2013 dengan jumlah data sebanyak 492 data. Data diambil melalui situs resmi Bank Indonesia pada bulan Februari 2014. Mean atau rata-rata sebesar 9965.445 dengan median data sebesar 9703.5 data terkecil atau min sebesar 8936, yaitu nilai kurs jual pada tanggal 2 Februari tahun 2012, sedangkan data kurs jual terbesar atau max yaitu sebesar 12331 pada tanggal 30 Desember 2013.

4.2 Analisis Pembentukan Persamaan SVR

Dalam Analisis SVR, untuk mengatasi masalah ketidaklinieran data dalam pembentukan model digunakan fungsi kernel atau kernel trik. Fungsi kernel yang digunakan adalah kernel Linier dan kernel Polynomial. Dimana di dalam fungsi Kernel tersebut diperlukan parameter-parameter kernel yang digunakan untuk mengoptimasikan hasil prediksi. Parameter kernel untuk Kernel Polynomial adalah d (*degree*). Nilai C diperlukan dalam pembentukan persamaan SVR dengan cara *trial and error* Untuk menghasilkan nilai R^2 dan MAPE terbaik.

4.2.1 Pembentukan Persamaan SVR Menggunakan Fungsi Kernel polynomial

Langkah pembentukan persamaan SVR dengan menggunakan fungsi Kernel Polynomial dibantu dengan *software MATLAB 2009a* adalah sebagai berikut :

1. Membagi keseluruhan data yang berjumlah 492 data menjadi data *training* dan data *testing*. Data *training* yang akan digunakan sebanyak 344 data dan data *testing* untuk prediksi sebanyak 147 data.
2. Pemilihan metode SVR yang digunakan adalah dengan fungsi kernel Polynomial dengan parameter $d = 1$ dan $C = 0.15$ untuk membentuk persamaan SVR.

- Setelah ditentukan fungsi kernel dan parameternya maka digunakan untuk memetakan data *training*.

Fungsi kernel polynomial dengan $d = 1$ yaitu

$$K(\mathbf{x}, \mathbf{x}_i) = (1 + \mathbf{x}^T \cdot \mathbf{x}_i)^1$$

$$\mathbf{x} = [x_1]^T$$

$$\mathbf{x}_i = [x_{1i}]^T$$

Sehingga didapatkan persamaan kernel sebagai berikut dan digunakan untuk pemetaan data *training*

$$(1 + \mathbf{x}^T \cdot \mathbf{x}_i) = (1 + x_1 x_{1i})$$


- Kemudian mendapatkan nilai beta untuk membentuk persamaan SVR melalui *Quadratic Programming* (QP) dengan bantuan software *MATLAB 2009a* yang outputnya dapat dilihat pada Lampiran 4.
- Mencari banyaknya *support vector* yang digunakan dalam memprediksi persamaan SVR dengan cara mencari nilai beta dengan toleransi = $\beta > C * 10^{-6}$, misalkan pada titik pertama nilai $\beta = 0.4974 * 10^{-6} >$ toleransi maka titik pertama disebut *support vector* dan digunakan dalam membentuk persamaan prediksi.
- Jumlah *support vector* yang terbentuk adalah sebanyak 271 data. Berarti 271 data *training* merupakan *support vector* dan dipakai dalam persamaan untuk memprediksi Kurs.
- Nilai beta selanjutnya digunakan dalam persamaan SVR untuk memprediksi data *testing*.

Selanjutnya berdasarkan hasil nilai β_i dan y_i dimasukkan ke dalam persamaan berikut

$$f(x) = (\sum_{i=1}^{271} \beta_i y_i \varphi(\mathbf{x}_i) \cdot \varphi(\mathbf{x}) + \text{bias}), \text{ dengan bias} = 0$$

$$= (0.0000004974 \times 9171 \times \varphi(x_1) \cdot \varphi(x)) + (0.0000004676 \times 9206 \times \varphi(x_2) \cdot \varphi(x)) + \dots (0.0000004427 \times 12250 \times \varphi(x_{271}) \cdot \varphi(x))$$

Sehingga didapat persamaan $f(x)$ untuk selanjutnya digunakan pada data *testing* sebagai prediksi. Dari perhitungan diatas dihasilkan persamaan prediksi pada data *testing* sebanyak 147 data yang outputnya dapat dilihat pada Tabel 4.4 yang merupakan prediksi Kurs untuk fungsi kernel polynomial. Untuk Kernel Linier dilakukan langkah analisis yang sama dengan fungsi Kernel polynomial.



Gambar 1. Plot Hasil Prediksi Data *Testing* terhadap Data Kurs Jual Kernel Polynomial

Berdasarkan Gambar 1 diketahui bahwa pola data *testing* dengan hasil prediksi memiliki pola yang sama. Hal ini dapat dilihat secara visual dan dengan melihat nilai akurasi R^2 sebesar 99.99% dan nilai MAPE sebesar 0.6135%. Hal ini membuktikan bahwa data *testing* dapat memprediksi nilai kurs secara akurat.

4.3 Perbandingan Hasil Akurasi Fungsi Kernel Linier dan Polynomial

Berdasarkan Tabel 1 diketahui akurasi dan error pada masing-masing fungsi kernel tidak jauh berbeda. Keduanya memberikan hasil yang cukup bagus yaitu pada fungsi kernel linier menghasilkan akurasi terbaik pada nilai $C = 0.15$ dengan $R^2 = 99.99\%$ dan nilai MAPE = 0.6131% pada data *testing*, sedangkan untuk fungsi kernel polynomial diketahui akurasi terbaik pada nilai $C = 0.15$ dan $d=1$ dengan $R^2 = 99.99\%$ dan MAPE = 0.6135% pada data *testing*.

Tabel 1 Perbandingan Akurasi Kernel Linier dengan Kernel Polynomial

No	C	Polynomial				Linier	
		d=1		d=2		MAPE(%)	R^2
		MAPE(%)	R^2	MAPE(%)	R^2		
1	0.1	1.2264	0.9998	100	-0.0000904	1.226	0.9998
2	1	100	-0.0000904	100	-0.0000904	100	-0.0000904
3	10	100	-0.0000904	100	-0.0000904	100	-0.0000904
4	100	100	-0.0000904	100	-0.0000904	100	-0.0000904
5	0.05	2.6675	0.9993	100	-0.0000904	2.6672	0.9993
6	0.15	0.6135	0.9999	0	0	0.6131	0.9999
7	0.2	1.0736	0.9999	0	0	1.073	0.9999
8	0.5	100	-0.0000904	0	0	100	-0.0000904

5. KESIMPULAN

Berdasarkan analisis yang telah dilakukan, diperoleh kesimpulan yaitu :

1. Prediksi Kurs Jual Rupiah terhadap Dollar Amerika Serikat menggunakan metode *Support Vector Regression* (SVR) dengan jumlah data training sebanyak 344 data menghasilkan akurasi yang cukup baik pada kedua fungsi kernel yang digunakan, yaitu kernel linier dan kernel polynomial. Pada kernel linier dihasilkan akurasi sebesar 100% dengan MAPE sebesar 0.3757%. Sedangkan fungsi kernel polynomial menghasilkan akurasi sebesar 100% dengan MAPE sebesar 0.4477%.
2. Pada pengujian dengan data testing sebanyak 147 data, akurasi prediksi yang didapat pada fungsi kernel linier yaitu 99.99% dengan MAPE sebesar 0.6131. Sedangkan menggunakan fungsi kernel *Polynomial* akurasi prediksi adalah sebesar 99.99 % dengan MAPE sebesar 0.6135%.
3. Dengan demikian prediksi Kurs Jual Rupiah menggunakan fungsi kernel Linier dan polynomial menghasilkan hasil yang tidak jauh berbeda, keduanya memberikan akurasi yang bagus dan error yang kecil.

DAFTAR PUSTAKA

- Abe, S. 2005. *Support Vector Machine for Pattern Classification*. Springer - Verlag. London Limited.
- Anonim. Bank Indonesia
<http://www.bi.go.id/id/moneter/informasi-kurs/transaksi-bi/Default.aspx>
diakses pada 3 Februari 2014.
- Anwary, A. A. 2011. *Prediksi Kurs Rupiah Terhadap Dollar Amerika Menggunakan Metode Fuzzy Time Series*. Skripsi. Tidak Dipublikasikan. Universitas Diponegoro: Semarang.
- Gunn, S. 1998. *Support Vector Machines for Classification and Regression*. Technical Report, ISIS.
- Hidayat, R. 2013. *Sistem Prediksi Status Gizi Balita Dengan Menggunakan Support Vector Regression*. Skripsi. Tidak Dipublikasikan. Institut Pertanian Bogor: Bogor.
- Katijaya, S. S. 2013. *Regresi Spline Sebagai Alternatif Dalam Pemodelan Kurs Rupiah Terhadap Dolar Amerika Serikat*. *Jurnal Gaussian* Vol. 2. No. 3. Hal 229-238, Universitas Diponegoro: Semarang.
- Larasati, R. 2012. *Prediksi Awal Musim Hujan Menggunakan Data Southern Oscillation Index Dengan Metode Support Vector Regression*. Skripsi. Tidak Dipublikasikan. Institut Pertanian Bogor: Bogor.
- Levi, D. M. 2004. *Keuangan Internasional*. Penerbit Andi: Yogyakarta.
- Mankiw, G. N. 2007. *Makroekonomi*. Penerbit Erlangga: Yogyakarta.
- Santosa, B. 2007. *Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Graha Ilmu: Yogyakarta.
- Santosa, B. 2007. *Data Mining Terapan dengan MATLAB*. Graha Ilmu: Yogyakarta.
- Scholkopf B., and Smola A. 2002. *Learning With Kernel*. MIT Press.
- Sukirno, S. 1994, *Teori Pengantar Makro Ekonomi*. Raja Grafindo Persada: Jakarta.
- Sukirno, S. 2002. *Pengantar Teori Ekonomi*. Raja Grafindo Persada: Jakarta.