

## OPTIMASI PARAMETER SUPPORT VECTOR MACHINES UNTUK PREDIKSI NILAI TUKAR RUPIAH TERHADAP DOLLAR AMERIKA SERIKAT

Ultach Enri

Dosen Tetap Universitas Singaperbangsa Karawang  
ultach@staff.unsika.ac.id

### ABSTRACT

*With an average daily turnover of \$ 5067 billion in April 2016 and \$ 5400 in April 2013, it has shown that foreign exchange market is the biggest market and most active of all financial markets which always move and never static. Therefore the prediction of volatility market is very important to secure investments, manage risks, and decide policies. This research aims to predict the value of exchange rate by using parameters optimization on Support Vector Machines(SVM) Algorithm is applied on it. SVM has been used widely for financial forecasting with time series data set and showed better performance than other algorithms in time series prediction.*

**Key Word** : Foreign Exchange, Support Vector Machines, Parameter Optimization, Kernels

### ABSTRAK

Dengan perkiraan omzet rata-rata harian USD 5067 miliar pada April 2016 dan sebesar USD 5400 pada April 2013, bisa di lihat bahwa pasar valuta asing merupakan pasar terbesar dan paling aktif dari semua pasar keuangan, yang selalu bergerak dan tidak pernah statis. Oleh karena ketidakstabilan itu maka sangat penting untuk mengamankan investasi, manajemen resiko dan juga kebijakan-kebijakan pengambil keputusan. Penelitian ini bertujuan untuk memprediksi nilai tukar mata uang dengan menggunakan optimasi parameter pada algoritma Support Vector Machines (SVM). SVM telah digunakan secara luas untuk peramalan keuangan yang menggunakan data set berupa time series serta menunjukkan performa yang lebih baik dari pada algoritma lainnya.

Kata Kunci : Nilai Tukar Mata Uang Asing, Support Vector Machines, Optimasi Parameter, Kernel

### PENDAHULUAN

Pada April 2016 Rata-rata omset harian perdagangan valuta asing diperkirakan sebesar USD 5067 miliar (Bank for International Settlements, 2016), hasil ini turun dari USD 5400 Miliar pada April 2013, bisa di lihat bahwa pasar valuta asing merupakan pasar terbesar dan paling aktif dari semua pasar keuangan, yang selalu bergerak dan tidak pernah statis, di mana pergerakan

tersebut bersifat acak. Dengan nilai tukar yang selalu bergerak, serta tidak terstruktur menjadikan prediksi pertukaran valuta asing menjadi salah satu yang paling sulit dan menuntut dibuatnya aplikasi peramalan keuangan yang mempunyai tingkat akurasi yang tinggi.

Teknik *computational intelligence* untuk memprediksi kurs nilai tukar telah populer di dalam beberapa tahun terakhir. Akhir-akhir ini teknik baru di dalam *computational intelligence*, yaitu *Support*

*Vector Machines*(SVM) telah digunakan di dalam pasar keuangan, dimana lebih efektif dari pada ANN (Kim, 2003; Thissen et al, 2003; Liu and Wang, 2008; Alamili, 2011). Prediksi dengan menggunakan SVM sangat sensitif terhadap nilai dari parameter-parameter, menjadi nilai soft-margin constant C berbagai parameter kernel. Alasan mengapa yang digunakan hanya teknik computational intelligence adalah karena karakteristik yang dimiliki teknik tersebut yang membedakan mereka dengan metode-metode tradisional sebelumnya, dan adanya peningkatan pupolaritas di dalam peramalan keuangan selama satu dekade terakhir. Kekuatan kemampuan generalisasi, menghasilkan output dari input yang tidak terlihat melalui pola-pola yang dihasilkan dari proses input sebelumnya, membuat pengelompokan menjadi sangat baik (Kecman, 2001).

SVM telah digunakan secara luas untuk peramalan keuangan yang menggunakan data set berupa *time series*(Sewll, Taylor, 2012) serta menunjukkan performa yang lebih baik dari pada algoritma lainnya termasuk ANN (Premanode, Toumazou, 2012) dimana ANN sudah terlebih dahulu banyak digunakan untuk proses peramalan termasuk sebagai alternatif yang menjanjikan untuk memprediksi nilai tukar mata uang asing (Yu, Wang, Huang, Keung Lai, 2007), dimana ANN menemukan solusi berupa lokal optimal sedangkan SVM menemukan solusi yang global optimal (Santosa, 2007), serta hasil yang diberikan oleh ANN akan selalu berbeda-beda setiap kali kita melakukan *training*,dikarenakan untuk proses *training* pada ANN berjalan dengan mengoreksi nilai *weights* secara berulang(Santosa, 2007) berbeda dengan SVM yang akan memberikan hasil yang selalu sama, dan juga SVM tidak tergantung pada dimensi ruang input yang membuat SVM fleksibel dalam pemilihan parameter (Premanode, Toumazou, 2012), yaitu parameter kernel dan juga parameter C, berbeda dengan ANN, banyak hal yang perlu di atur nilai parameternya seperti jumlah *hidden layer*, *neuron* untuk *hidden*

*layer*, metode untuk *training*, dan lain lain (Santosa, 2007) dan juga SVM cocok untuk menangani data set yang besar dan kompleks sepertinya halnya prediksi nilai mata uang asing, hal ini juga diperkuat dari penelitian yang di lakukan oleh Alamili, 2011. Di dalam SVM, pemilihan parameter C,  $\sigma$ ,  $\epsilon$  memberikan dampak yang sangat besar bagi performace SVM(Wei Fei, Bin Miao, Liang Liu, 2009).

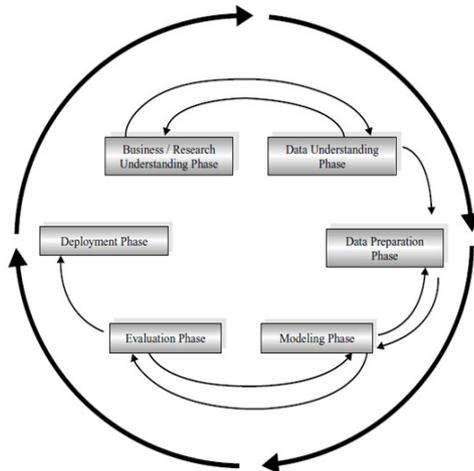
## TINJAUAN PUSTAKA

### 2.1 Data Mining

Data mining sering juga di sebut *knowledge discovery in database*(KDD), adalah kegiatan yang meliputi pengumpulan, pemakaian data historis untuk menemukan keteraturan, pola atau hubungan dalam set data berukuran besar (Santosa 2007), yang disimpan di dalam repositori, menggunakan teknologi pengenalan pola dan juga teknik statistik dan matematika (Larose, 2005), Dengan kata lain data mining mempunyai kegiatan utama yaitu mengumpulkan, menemukan, dan menggali atau menambang pengetahuan dari data.

Fungsi-fungsi yang terdapat dalam data mining adalah (Larose, 2005) : Fungsi deskripsi (*Description*), Fungsi estimasi (*Estimation*), Fungsi prediksi (*Prediction*), Fungsi klasifikasi (*Classification*), Fungsi pengelompokan (*Clustering*), Fungsi asosiasi (*Associaton*).

*Cross-Industry Standard Process for Data Mining* (CRISP-DM) dikembangkan tahun 1996 oleh analis yang mewakili DaimlerChrysler, SPSS dan NCR. CRISP-DM menyediakan kepemilikan dan tersedia proses standar yang bebas untuk data mining yang sesuai sebagai strategi pemecahan masalah secara umum dari bisnis atau unit penelitian. Dalam CRISP-DM, Sebuah proyek *data mining* memiliki siklus hidup yang terbagi dalam enam fase (Gambar 2.1).



**Gambar 2.1** Proses Data Mining menurut CRISP-DM (Larose, 2005)

## 2.2 Support Vector Machine

SVM merupakan salah satu teknik yang relatif baru untuk melakukan prediksi, SVM berada dalam satu kelas dengan ANN dalam hal fungsi dan kondisi permasalahan yang bisa di selesaikan (Santosa, 2007). SVM diperkenalkan pada *Conference on Learning Theory (COLT)* oleh Boser, Bernhard, Guyon, dan Vapnik tahun 1992, (Premanode, Tzoumazou 2012) yaitu sebuah teknik *supervised learning* dari bidang *machine learning* yang dapat di aplikasikan kedalam klasifikasi dan regresi (Sewell, Taylor 2012).

Yang menjadi karakteristik dari *Support Vector Machine (SVM)* adalah sebagai berikut:

1. Secara prinsip SVM adalah *linear classifier*.
2. *Pattern recognition* dilakukan dengan mentransformasikan data pada *input space* ke ruang yang berdimensi lebih tinggi, dan optimisasi dilakukan pada ruang vector yang baru tersebut. Hal ini membedakan SVM dari solusi *pattern recognition* pada umumnya, yang melakukan optimisasi parameter pada ruang hasil transformasi yang berdimensi lebih rendah daripada dimensi *input space*.

3. Menerapkan strategi *Structural Risk Minimization (SRM)*.

4. Prinsip kerja SVM pada dasarnya hanya mampu menangani klasifikasi dua *class*.

Secara sederhana konsep SVM adalah sebagai usaha mencari *hyperlane* terbaik yang berfungsi sebagai pemisah dua buah *class* pada *input space*.

Banyak teknik data mining atau machine learning yang dikembangkan dengan asumsi kelinearan, sehingga algoritma yang di hasilkan terbatas untuk kasus-kasus yang linear, maka untuk mengatasinya kita bisa menggunakan metode kernel. Fungsi kernel yang biasa digunakan dalam SVM :

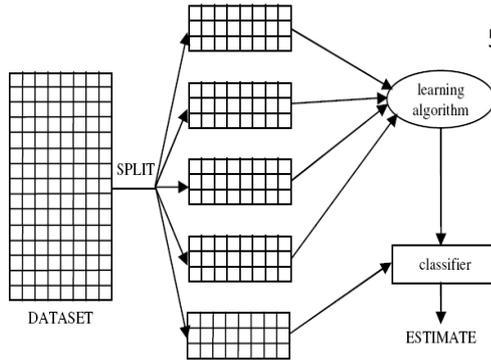
- a. *Linear* :  $x^T x$ ,
- b. *Polinomial* :  $(x^T x_i + 1)^p$ ,
- c. *Radial basis function (RBF)* :  $\exp\left(-\frac{1}{2\sigma^2} \|x-x_i\|^2\right)$ ,
- d. *Tangent hyperbolic (sigmoid)* :  $\tanh(\beta x^T x_i + \beta_1)$ , dimana  $\beta, \beta_1 \in \mathbb{R}$  ?

Fungsi kernel mana yang harus digunakan untuk substitusi dot product di *feature space* sangat bergantung pada data. Biasanya metode *cross validation* (Santosa 2007) digunakan untuk pemilihan fungsi kernel.

## 2.3 Pengujian K-Fold Cross Validation

Salah satu pendekatan alternatif untuk “train dan test” yang sering di adopsi dalam beberapa kasus (dan beberapa lainnya terlepas dari ukurannya) yang di sebut dengan k-fold cross validation (Bramer, 2007), dengan cara menguji besarnya error pada data test (santosa, 2007). Kita gunakan k-1 sampel untuk training dan 1 sampel sisanya untuk testing. Misalnya ada 10 subset data, kita menggunakan 9 subset untuk training dan 1 subset sisanya untuk testing. Ada 10 kali training dimana pada

masing-masing training ada 9 subset data untuk training dan 1 subset digunakan untuk testing. Dari situ lalu di hitung rata-rata error dan standar deviasi error (Santosa, 2007). Setiap bagian k pada gilirannya digunakan sebagai ujian menetapkan dan k lainnya - 1 bagian digunakan sebagai training set (Bramer, 2007), Seperti terlihat pada gambar 2.2



Gambar 2.2. K-fold Cross-validation

**2.5 Evaluasi**

Dalam prediksi keberhasilan suatu proses dapat diukur selain dari hasil percobaan yang akurat dan optimal tetapi juga harus diperhitungkan kesalahan(error), berikut adalah error yang sering di gunakan(Santosa, 2007):

1. Mean Squared Error (MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \tag{1}$$

2. Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{\sum_{i=1}^m APE_i}{m} \tag{2}$$

Dimana

$$APE = \frac{\sum_{i=1}^m |y_i - \hat{y}_i|}{y_i} \cdot 100 \tag{3}$$

3. Mean Absolute Deviation (MAD)

$$MAD = \frac{\sum_{i=1}^m |y_i - \hat{y}_i|}{m} \tag{4}$$

4. Sum Square Error (SSE)

$$SE = \sum_{i=1}^n (D_{ij} - f_j(X_i))^2 \tag{5}$$

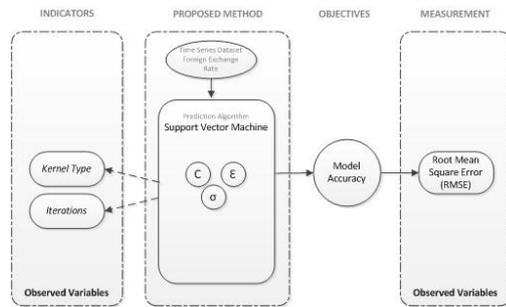
5. Root Mean Square Error (RMSE)

$$RMSE = \sqrt{\frac{SSE}{N+K}} \tag{6}$$

6. Normalized Mean Absolute Error (NMAE)

$$NMAE = \frac{MAE}{\bar{P}} = \frac{\sum_{t=1}^N |e(t+k|t)|}{\sum_{t=1}^N P(t)} \tag{7}$$

**METODOLOGI PENELITIAN**



Gambar 3.1 Kerangka Pemikiran

Berdasarkan gambar 3.1, penelitian ini bertujuan untuk meneliti dengan menggunakan Algoritma SVM yang bertujuan untuk mengoptimasi parameter di dalam SVM dapat meningkatkan akurasi dari prediksi mata uang asing, dimana yang akan di gunakan adalah USD/IDR. Untuk pengujian hasil prediksi digunakan *x-validation*, menggunakan sepuluh langkah(*ten folds cross-validation*), dimana data akan dibagi

menjadi sepuluh data dengan jumlah yang sama kemudian akan diambil satu persatu untuk test, dan sembilan bagian lainnya digunakan untuk training. Dengan menggunakan *x-validation* akurasi hasil prediksi akan lebih terjamin karena mengurangi data yang tidak konsisten dalam proses prediksi. Serta akan menggunakan *Root Mean Square Error*(RMSE) dan *Normalized Mean Absolute Error*(NMAE) sebagai metode evaluasi.

### 3.1. Analisa Kebutuhan

Jenis penelitian yang digunakan dalam penelitian ini adalah model eksperimen. Penelitian eksperimen ini menggunakan algoritma SVM untuk memprediksi nilai tukar mata uang asing dimana yang akan digunakan adalah USD/IDR. Jenis data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh penulis dari [www.oanda.com](http://www.oanda.com) dimana menyediakan data-data tentang nilai tukar mata uang asing seluruh negara, sedangkan *software* yang digunakan sebagai alat bantu dalam penelitian ini adalah *Rapidminer 5.3* dan *Microsoft Excel 2007*.

### 3.2. Desain Penelitian

Pada penelitian ini akan digunakan algoritma *Support Vector Machine* untuk optimasi parameter, berikut adalah langkah-langkah yang digunakan : Pengumpulan Data, Pengolahan Data (Cleaning Data, Normalisasi dan Windowing), Metode yang digunakan, Eksperimen dan Pengujian Model, Evaluasi. Data yang digunakan dalam penelitian ini adalah data nilai tukar mata uang asing selama enam tahun, yaitu dari 1 januari 2008 sampai dengan 31 desember 2013, data yang dikumpulkan adalah nilai tukar perhari, sehingga terdapat sebanyak 2.192 *records*. Pembagian data untuk penelitian ini dibagi menjadi dua bagian, yaitu data *training* dan data *testing*. Data yang akan digunakan untuk *training* adalah 70% dari data yang sudah dikumpulkan dan 30% sebagai *testing*. Pada penelitian ini

metode yang akan diusulkan adalah dengan menggunakan *Support Vector Machine*(SVM).

Setelah dilakukan proses *cleaning*, normalisasi, *windowing*, pembagian data, dan juga telah mendapatkan kombinasi-kombinasi optimasi parameter  $C$ ,  $\gamma$  dan  $\epsilon$ , selanjutnya hasil dari proses optimasi tersebut akan di aplikasikan dengan menggunakan algoritma SVM selanjutnya hasil yang didapat akan divalidasi dengan *10 folds x-validation*, untuk mendapatkan *Root Mean Squared Error*(RMSE) dan *Normalized Mean Absolute Error*(NMRE).

Tahap eksperimen yang dilakukan adalah sebagai berikut :

#### 1. Inisialisasi Parameter $C$ , $\gamma$ dan $\epsilon$

Menentukan nilai parameter  $C$ ,  $\gamma$  dan  $\epsilon$  yang kemudian akan di dapat parameter yang optimal untuk mendapatkan hasil terbaik. Semakin besar parameter  $C$  semakin besar finalisasi error untuk memaksimalkan margin (alamili, 2011) oleh karena itu parameter  $C$  ditetapkan adalah 0 – 500, untuk parameter  $\gamma$  dikarenakan semakin besar  $\gamma$  semakin bagus nilai prediksi pada training dan semakin buruk pada validasi(alamili, 2011)maka di tetapkan range untuk  $\gamma$  adalah 0.01 – 1 dan range yang sama akan digunakan untuk parameter  $\epsilon$  0.01 – 1. Untuk optimasi parameter pada *Rapidminer* menggunakan operator *Optimize Parameters*, nilai untuk *max generations* adalah 50, *Tournament fraction* adalah 0.25 dan *crossover prob* adalah 0.9, *Population* sebanyak 5. Dari kombinas-kombinasi parameter akan di masukkan kedalam algoritma SVM, lalu kombinasi yang memberikan nilai akurasi serta RMSE dan NMAE terbaik.

#### 2. Pemilihan Kernel

Pemilihan kernel berpengaruh terhadap tingkat akurasi serta *root mean squared error*. Kernel yang akan digunakan dalam penelitian ini adalah *Dot*, *Polynomial* dan *RBF*. Dari parameter-parameter yang didapat dari hasil optimasi parameter akan di uji dengan menggunakan masing-masing algoritma dengan menggunakan kernel

tersebut, maka akan terlihat kernel manakah yang paling sesuai dengan data set kita dan mana yang bisa memberikan hasil akurasi yang optimal.

3. Penggunaan Algoritma SVM

Setelah optimasi parameter dan juga pemilihan kernel langkah selanjutnya adalah menggunakan algoritma yang sudah di pilih, yaitu SVM. Setelah diperoleh model dari hasil *training*, maka akan dilakukan evaluasi terhadap model tersebut. Proses evaluasi akan dilakukan dengan menggunakan *cross validation*, dengan menguji model yang terbentuk dengan data secara acak yang dipisahkan dengan menggunakan 10 *folds cross validation*. Untuk pengukuran akurasi (*Measurements*) akan menggunakan *Root Mean Squared Error*(RMSE) dan *Normalized Mean Absolute Error*(NMAE), dengan menguji model prediksi yang dianggap paling optimal yang terbentuk dengan algoritma SVM.

**HASIL PENELITIAN DAN PEMBAHASAN**

Penelitian dilakukan dengan menggunakan algoritma *Support Vector Machine*(SVM). Pengujian model dengan menggunakan kombinasi parameter *C*,  $\gamma$  dan  $\epsilon$  yang diperoleh dari proses optimasi parameter.masing-masing kombinasi parameter tersebut akan di uji dengan menggunakan kernel *Dot*, *Polynomial* dan *Radial Bases Function*(RBF). Hasil dari masing-masing eksperimen akan dibandingkan.

Kombinasi parameter yang di dapatkan adalah sebagai berikut :

**Tabel 4.1** . Kombinasi Optimasi Parameter

USD/IDR		
Gamma	C	Epsilon
0.0316464	200.5376932	0.026989196
0.094297355	30.80548455	0.07233275
0.026420875	484.2464109	0.060586312
0.016188696	110.2519166	0.053619431
0.066104254	431.6781738	0.060815857
0.019435688	110.2433957	0.056477776
0.01	484.2447979	0.06906595

0.022636224	110.2596923	0.055117068
0.01	484.2240223	0.05713919
0.012803128	110.2454817	0.061577892
0.035643024	484.258259	0.067139711
0.030351172	110.2542499	0.039492137
0.040287444	484.2272948	0.049781901
0.018281166	110.2550363	0.05435641
0.026420875	110.2519166	0.060586312
0.016188696	484.2464109	0.053619431
0.026420875	110.2519166	0.053619431
0.016188696	484.2464109	0.060586312
0.024884294	110.2463438	0.069888856
0.030368863	110.2632237	0.049353811
0.021256881	110.2689748	0.079133896
0.038075853	110.2513764	0.052583208
0.045781849	110.2329106	0.060271133
0.022416572	110.258697	0.055460617
0.011938636	110.2372378	0.058179287
0.019435688	110.2433957	0.060586312
0.026420875	110.2519166	0.056477776
0.026960439	110.2647213	0.054039713
0.021256207	110.2490559	0.057588867
0.037730288	110.2528524	0.050848301
0.03884461	110.2490256	0.071691483
0.026624406	110.2510099	0.073658126
0.037754807	110.2628213	0.059468064
0.019863723	110.2356983	0.056472367
0.029298947	110.2452521	0.039681542
0.021644842	110.2701674	0.060775355
0.024884294	110.2519166	0.060586312
0.026420875	110.2463438	0.069888856
0.026420875	110.2463438	0.060586312
0.024884294	110.2519166	0.069888856
0.031660798	110.253219	0.067668837
0.027792247	110.255855	0.033625999
0.026017647	110.2602927	0.060782671
0.023861162	110.2432185	0.037631317
0.042969886	110.2576226	0.075312351
0.01	110.2578492	0.04845634
0.025019815	110.2508708	0.057482962
0.018842491	110.2436939	0.058287755
0.026912282	110.2616612	0.049671422
0.026960439	110.2647213	0.060586312

0.026420875	110.2519166	0.054039713
0.029298947	110.2647213	0.054039713
0.026960439	110.2452521	0.039681542
0.027845228	110.2636722	0.066004975
0.034665391	110.2595968	0.040613375
0.01348075	110.2717075	0.040667912

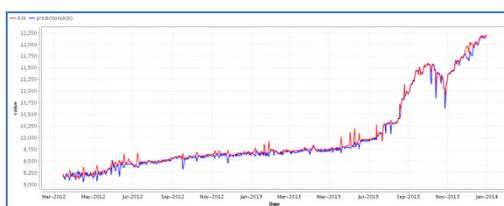
0.020129506	110.2659262	0.042951915
0.019042742	110.2394434	0.054659955
0.034747731	110.2684507	0.060516185
0.032198918	110.2740642	0.073325243
0.026960439	110.2647213	0.054039713
0.026960439	110.2647213	0.054039713

Dari hasil-hasil eksperimen dengan menggunakan kombinasi kombinasi parameter diatas maka didapatkan hasil pengujian terbaik dengan menggunakan kernel-kernel SVM yang terlihat pada tabel di bawah ini.

**Tabel 4.2. Hasil Eksperimen Terbaik USD/IDR SVM**

	RBF		Dot		Polynomial	
	Training	Testing	Training	Testing	Training	Testing
Gamma	0.016188696		0.021256881		0.040287444	
C	484.2464109		110.2689748		484.2272948	
Epsilon	0.053619431		0.079133896		0.049781901	
Bias	10454.423	10438.314	9463.212	10011.387	9116.795	9603.571
RMSE	63.014	66.589	69.439	69.196	495.029	417.929
NMAE	0.055	0.052	0.063	0.047	0.614	0.378
Prediction Accuracy	82.1	78.2	80.8	80.4	53	57

Dari hasil eksperimen di atas terlihat bahwa kernel RBF untuk kedua pertukaran mata uang memberikan hasil yang lebih baik dari pada kernel Dot dan Polynomial. Dimana pada USD/IDR dengan nilai  $C = 484.2464109$ ,  $\gamma = 0.016188696$ ,  $\epsilon = 0.053619431$  memberikan nilai akurasi yang terbaik.



**Gambar 4. Hasil Eksperimen Data Testing USD/IDR SVM**

Berdasarkan hasil eksperimen yang dilakukan untuk memprediksi nilai tukar mata uang, dapat disimpulkan bahwa eksperimen dengan menggunakan algoritma SVM di mulai dengan mencari nilai-nilai parameter  $C$ ,  $\gamma$  dan  $\epsilon$  yang dapat memberikan nilai akurasi yang terbaik, dengan cara mencari melalui optimasi parameter dengan memasukkan range 0 –

500 untuk parameter  $C$ , 0.01- 1 untuk parameter  $\gamma$  dan  $\epsilon$ , nilai untuk *max generations* adalah 50, *Tournament fraction* adalah 0.25 dan *crossover prob* adalah 0.9, *Population* sebanyak 5.

Selanjutnya hasil dari kombinasi parameter-parameter tersebut di uji coba dengan menggunakan algoritma SVM dan menggunakan kernel-kernel yang terdapat pada SVM yaitu, RBF, Dot dan Polynomial. Dari eksperimen tersebut di dapatkan hasil akurasi terbaik dengan menggunakan kernel RBF. Pada USD/IDR didapat akurasi 82.1%, RMSE = 63.014 dan NMAE = 0.055 pada data *training* dan 78.2%, RMSE = 66.589 dan NMAE = 0.052 pada data *testing* dengan nilai  $C = 484.2464109$ ,  $\gamma = 0.016188696$  dan  $\epsilon = 0.053619431$ .

**KESIMPULAN**

Dari hasil penelitian yang dilakukan dari tahap awal hingga pengujian penerapan SVM untuk memprediksi nilai tukar mata uang, telah didapatkan jawaban dari pertanyaan-pertanyaan penelitian yang telah diidentifikasi sebelumnya, yaitu :

- d. Parameter-parameter yang dapat memberikan hasil yang optimal adalah  $C = 484.2464109$ ,  $\gamma = 0.016188696$  dan  $\epsilon = 0.053619431$  untuk USD/IDR.
- e. Dari eksperimen yang dilakukan terlihat bahwa kernel yang memberikan hasil terbaik adalah RBF pada USD/IDR dengan akurasi dari kernel RBF sebesar 82.1% untuk *training*, 78.2% untuk *testing*, kernel Dot sebesar 80.8% untuk *training*, 80.4% untuk *testing* dan kernel

Polynomial sebesar 53% untuk *training*, 57% untuk *testing*.

Pada penelitian ini secara umum penerapan algoritma SVMPSO dapat meningkatkan akurasi prediksi nilai tukar mata uang, akan tetapi karena keterbatasan penelitian ini perlu disarankan untuk melakukan penelitian selanjutnya untuk mendapatkan akurasi yang lebih baik. Adapun saran-saran yang dapat diberikan, yaitu :

- a. Penggunaan normalisasi dengan metode yang berbeda terutama untuk kasus seperti pertukaran USD/IDR yang mempunyai range berbeda dengan mata uang asing lainnya, agar dapat meminimalisasi nilai RMSE.
- b. Penggunaan algoritma yang berbeda untuk penelitian sejenis dengan menerapkan nilai parameter-parameter dan iterasi yang berbeda-beda.
- c. Penelitian ini dapat dikembangkan dengan menggunakan metode optimasi, seperti *Particle Swarm Optimization* (PSO), *Genetic Algorithm* (GA), *Simulated Annealing* (SA), *Ant Colony Optimization* (ACO) serta *Artificial Bee Colony Algorithm* (ABC).

#### DAFTAR PUSTAKA

- [1] Alamili, M., (2011). Exchange Rate Prediction using Support Vector Machines. Technische Universiteit Delft.
- [2] Bank for International Settlements (2016). Triennial Central Bank Survey of foreign exchange and OTC derivatives market in 2016. Source : <https://www.bis.org/publ/rpfx16.htm?m=6%7C381%7C677>
- [3] Bramer, M., (2007). Principles of Data Mining. London : Springer.
- [4] Kecman, V., (2001). Learning and Soft Computing. The MIT Press Cambridge, Massachusetts London, England.
- [5] Kim, K. (2003). Financial time series forecasting using Support Vector Machines.
- [6] Larose, D. T., (2005). “Discovering Knowledge in Data,” . Canada : Wiley Interscience .
- [7] Liu, L. and Wang, W. (2008). *Exchange Rates Forecasting with Least Squares SVM*. International Conference on Computer Science and Software Engineering.
- [8] Premanode, B. and Toumazou, C., (2012) “Improving prediction of exchange rates using Differential EMD,” *Expert Systems with Applications*, vol. 40, no. 1, pp. 377–384.
- [9] Oanda Corporation (2013). Historical foreign exchange data . Source: <https://fxtrade.oanda.com/trade-forex/fxtrade/historical-data>
- [10] Santosa, B., (2007). Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis. Yogyakarta : Graha Ilmu.
- [11] Sewell, M. and Shawe-Taylor, J., (2012). “Forecasting foreign exchange rates using kernel methods,” *Expert Systems with Applications*, vol. 39, no. 9, pp. 7652–7662.
- [12] Thissen, U., van Brakel, R., de Weijer, A.P., Melssen, W.J., Buydens, L.M.C. (2003). *Using support vector machines for time series prediction. Chemometrics and Intelligent Laboratory Systems*.
- [13] Wei Fei, S., Bin Miao, Y. and Liang Liu, C., (2009). Chinese Grain Production Forecasting Method Based on Particle Swarm Optimization-based Support Vector Machine, Recent Patents on Engineering.
- [14] Yu, L., Wang, S., Huang, W. and Keung Lai, K., (2007). “Are Foreign Exchange Rates Predictable? A Survey From Artificial Neural Networks Perspective,” *Scientific Inquiry*, vol. 8, no. 2, pp. 207 – 228