

# METODE SUPPORT VECTOR MACHINE DAN FORWARD SELECTION PREDIKSI PEMBAYARAN PEMBELIAN BAHAN BAKU KOPRA

Ivo Colanus Rally Drajana  
ivocolanusrally@gmail.com  
Universitas Ichsan Gorontalo

## Abstrak

Telah banyak peneliti-peneliti termotivasi dalam meningkatkan kinerja performa prediksi. *Support Vector Machine* (SVM) metode yang berlandaskan pada teori pembelajaran *statistic* dan memberi hasil yang menjanjikan akan lebih baik dibanding metode lain. SVM bekerja juga dengan baik terhadap data yang berdimensi tinggi dengan menggunakan teknik *kernel*. Penentuan variabel yang relevan sangat dibutuhkan untuk dapat memberikan kinerja performa lebih efektif lagi pada suatu model. Pada penelitian ini bermaksud untuk mengembangkan model prediksi dengan mengkombinasikan algoritma *Support Vector Machine* dengan *Feature Selection*, khususnya *forward selection* dalam memprediksi pembayaran pembelian bahan baku kopra. Model yang diusulkan dievaluasi menggunakan data *time* pembelian bahan baku kopra. Hasil eksperimen penelitian ini menunjukkan dimana *series* pembayaran algoritma SVM dan *Forward Selection* memberikan kinerja performa yang terbaik dibandingkan SVM, SVM dan *Backward Elimination* serta BPNN dan *Feature Selection*.

**Kata Kunci:** *Support Vector Machine* (SVM), *Forward Selection* (FS), *Time Series*, Prediksi

## 1. Pendahuluan

Pembayaran adalah cara yang berhubungan dengan pemindahan sejumlah nilai uang dari salah satu pihak ke pihak lainnya. Pembayaran adalah salah satu bentuk transaksi keuangan. Transaksi eksternal transaksi yang terjadi diantara perusahaan dengan pihak luar sedangkan transaksi yang internal transaksi hanya terjadi didalam unit perusahaan[1]. Kegiatan pembelian bahan baku adalah salah satu hal terpenting didalam suatu proses perbisnisan. Kopra adalah salah satu jenis bahan baku yang siap olah. Bahan baku kopra dapat diperoleh secara langsung dari sumber alam. Hasil olahan komoditi kelapa beruba kopra merupakan bahan baku bagi perusahaan minyak kelapa dalam *Crude Coconut Oil* yang kemudian diproses menjadi produk lebih berkualitas seperti minyak yang telah melewati tahap proses *Refinery*, *Bleaching*, dan *Deodorize* (RBD) [2]. Pembayaran pembelian bahan baku kopra tiap harinya atau minggunya mengalami perubahan fluktuatif. Dalam melakukan peramalan metode yang umum digunakan adalah metode *time series*, nilai dimasa yang akan datang dapat diketahui berdasarkan urutan waktu pengamatannya. Metode *time series* memiliki kemampuan yang tinggi dengan cara melihat nilai dari masa lalu[3].

Algoritma *Support vector machine* (SVM) memiliki kelebihan dalam menunjukkan performa yang sangat baik untuk prediksi *time series*[4]. Algoritma SVM adalah metode yang berlandaskan pada teori pembelajaran *statistic* dan memberi hasil yang menjanjikan akan lebih baik dibanding metode lain. SVM bekerja juga dengan baik terhadap data yang berdimensi tinggi dengan menggunakan teknik *kernel*[5]. Metode SVM tidak menghasilkan hasil yang akurat ketika banyak fitur yang tidak relevan, tidak semua fitur diperlukan dalam proses. Seleksi fitur bekerja secara langsung mengurangi jumlah fitur dan memilih fitur yang benar-benar memberikan informasi, jumlah fitur berkurang secara signifikan dan masalah *overfitting* teratasi. Metode SVM memberikan kinerja yang efektif, ketika fitur yang tidak relevan dihilangkan[6]. Algoritma *forward selection* dapat mengoptimalkan variabel yang akan dimasukkan kedalam model. Performa metode *forward selection* lebih baik dibandingkan dengan metode *backward elimination* serta mendapatkan model yang lebih baik dalam memprediksi[7]. Penelitian ini memiliki tujuan menerapkan model prediksi menggunakan algoritma SVM dan *Forward Selection* untuk meramalkan pembayaran pembelian bahan baku kopra. Peneliti juga membandingkan algoritma yang diterapkan dengan metode *Backpropagation Neural Network* (BPNN).

## 2. Landasan Teori

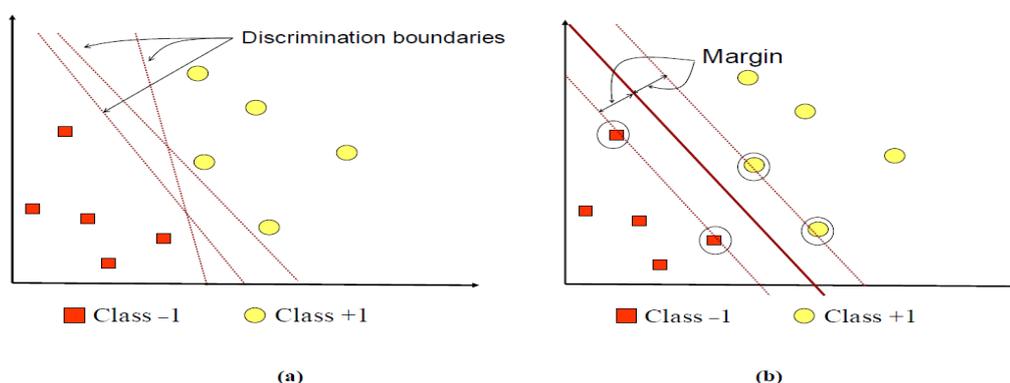
### 2.1. Feature Selection

*Forward Selection* salah satu prosedur berstep yang memiliki tujuan untuk menggandakan variabel yang dikendalikan satu demi satu ke dalam persamaan yang dilandaskan pada *alpha* tertentu buat masukan. *Alpha* buat masukan merupakan nilai yang yang menjadi tolak ukur apakah salah satu

predictor yang saat ini tidak dalam model, harus ditambahkan ke model[8]. *Backward Elimination* adalah salah satu metode yang memiliki fungsi untuk pengoptimalan kinerja suatu model dengan cara kerja system pemilihan mundur. Dalam pemilihan variabel ini dilakukan dengan cara pemilihan mundur yaitu menguji semua variabel setelah itu menghapus variabel-variabel yang dianggap tidak relevan. Variabel yang diproses, jika dianggap tidak signifikan atau berpengaruh didalam model maka akan dihapuskan dari model. Proses eliminasi ini akan dihentikan jika semua variable yang telah masuk selesai diproses[9].

## 2.2. Support Vector Machine

*Support Vector Machine* (SVM) kali pertama diperkenalkan oleh Vapnik tahun 1992 sebagai rangkaian harmonis konsep-konsep utama didalam bidang *pattern recognition*. Secara sederhana konsep SVM dapat dijelaskan sebagai usaha mencari *hyperplane-hyperplane* terbaik yang berfungsi sebagai pemisah dua buah *class* pada input space[10].



Gambar 1. SVM Berusaha Menemukan *Hyperplane* Terbaik

Gambar 1a memperlihatkan beberapa *pattern* yang merupakan anggota dari dua buah *class* : +1 dan -1. *Pattern* yang tergabung pada *class* -1 disimbolkan dengan warna merah, sedangkan *pattern* pada *class* +1, disimbolkan dengan warna kuning. Problem klasifikasi dapat diterjemahkan dengan usaha menemukan garis (*hyperplane*) yang memisahkan antara kedua kelompok tersebut. Berbagai alternatif garis pemisah (*discrimination boundaries*) ditunjukkan pada gambar 1a. *Hyperplane* pemisah terbaik antara kedua *class* dapat ditemukan dengan mengukur *margin hyperplane* tersebut dan mencari titik maksimalnya. *Margin* adalah jarak antara *hyperplane* tersebut dengan *pattern* terdekat dari masing-masing *class*. *Pattern* yang paling dekat ini disebut sebagai *support vector*. Garis solid pada gambar 1b menunjukkan *hyperplane* yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua *class*, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam adalah *support vector*. Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada SVM.

Proses pembelajaran SVM adalah untuk menentukan *support vector*, kita hanya cukup mengetahui fungsi kernel yang dipakai, dan tidak perlu mengetahui wujud dari fungsi *non-linear*. Persamaan SVM:

$$f(x) = w^t \phi(x) + b \quad (1)$$

Dimana:

- $b$  = Bias
- $x = (x_1, x_2, \dots, x_D)^T$  = Variabel Input
- $w = (w_0, w_1, \dots, w_D)^T$  = Parameter Bobot
- $\phi(x)$  = Fungsi Transformasi fitur

SVM adalah algoritma yang memiliki kelas metode kernel, yang berakar pada teori belajar statistik. Kernel berfungsi sebagai dasar pembelajaran semua algoritma, algoritma ini bertujuan umum masalah fungsi kernel tertentu. Karena mesin *linear* hanya dapat mengklasifikasi data dalam *linear* ruang fitur terpisah. Fungsi peran kernel untuk mendorong sebuah ruang fitur oleh implisit pemetaan data pelatihan kedalam ruang dimensi yang lebih tinggi dimana data adalah *linear* terpisah. Tujuan dari SVM adalah untuk merancang cara pembelajaran komputasi yang efisien dalam pemisahan

*hyperplane* didalam ruang fitur berdimensi tinggi[11]. Dalam algoritma SVM ada *trik kernel* dimana ada SVM *linear* dan SVM *nonlinear*. Dimana SVM adalah *hyperplane linear* yang bekerja hanya pada data yang hanya dapat dipisahkan dengan *caralinear*. SVM *nonlinear* yaitu data yang berdistribusi pada kelas yang tidak *linear* sering digunakan pendekatan kernel pada fitur awal data set. Dimana kernel dapat diartikan sebagai suatu fungsi yang memetakan fitur data yang memiliki dimensi awal rendah fitur lainnya yang berdimensi lebih tinggi bahkan jauh lebih tinggi. Masalah data yang sifatnya tidak *linear*, kita memerlukan penggunaan fungsi kernel[12].

Fungsi kernel *Polynomial*

$$K(x, y) = (x \cdot y + c)^d \quad (2)$$

Dimana.

$(x, y)$  = Vektor Input

$c$  = Variabel

$d$  = Derajat *polynomial*

### 2.3. Backpropagation Neural Network (BPNN)

Algoritma *Neural Network* adalah salah satu metode yang bekerja berlandaskan cara kerja pada otak manusia. Informasi dikirimkan ke *neuron* melalui suatu *input* pembobotan. Langkah selanjutnya memproses *input* oleh fungsi *propagation* yang akan menaikkan nilai *input* bobot. Kemudian hasil akan dibandingkan dengan *threshold* oleh fungsi aktivasi, jika didapati *input* melewati batas *threshold*, maka *neuron* diaktifkan, namun jika tidak *neuron* akan di *inhibit*. Jika *neuron* diaktifkan, maka *neuron* akan mengirim *output* dengan cara melalui pembobotan *output* ke *neuron* lainnya, demikian seterusnya. *Neural Network* didalam *data mining* dipergunakan untuk proses peramalan kelas suatu data uji baru yang ditemukan[13]. Metode *backpropagation* merupakan salah satu metode pelatihan paling terpopuler. *Backpropagation* sering digunakan dalam menyelesaikan permasalahan, yang salah satunya adalah prediksi. Cara kerja pelatihan metode *backpropagation* sama dengan *perceptron* dimana sejumlah data latih sebagai pola masukan dikirimkan pada jaringan kemudian menghitung pola keluaran namun jika ditemukan *error* maka bobot didalam jaringan akan diperbaharui yang bertujuan untuk mengurangi *error* tersebut. Dimana *error* merupakan perbedaan anatar target keluaran yang diharapkan dengan nilai keluaran[14].

### 2.4. Root Mean Square Error

Untuk mendapatkan hasil keakuratan dari sebuah peramalan, diperlukan evaluasi terhadap data yang sebenarnya. Ada beberapa metode yang sering digunakan untuk melakukan perhitungan kesalahan peramalan salah satunya adalah *root mean square error* (RMSE), metode ini sering digunakan dalam mengevaluasi hasil peramalan. Ukuran yang sering digunakan dari perbedaan antara nilai-nilai diprediksi oleh model atau estimator dan nilai-nilai benar-benar diamati yaitu RMSE. Perbedaan-perbedaan individual disebut residual ketika perhitungan dilakukan atas sampel data yang digunakan untuk estimasi, dan disebut kesalahan prediksi ketika dihitung *out-of-sample*. RMSE memiliki fungsi untuk agregat besaran kesalahan dalam prediksi untuk berbagai kali menjadi ukuran tunggal daya prediksi. RMSE merupakan ukuran akurasi yang baik, tapi hanya untuk membandingkan kesalahan peramalan model yang berbeda untuk variabel tertentu dan tidak antara variabel, karena skala-dependent[15]. MenurutRaharja, A[16], berikut persamaan *root means square error* (RMSE).

$$RMSE = \sqrt{\frac{\sum(y_t - \hat{y}_t)^2}{n}} \quad (3)$$

Dimana:

**RMSE** = Root Mean Square Error

$n$  = Jumlah Sampel

$y_t$  = Nilai Aktual Indeks

$\hat{y}_t$  = Nilai Prediksi Indeks

### 2.5. Data Time Series

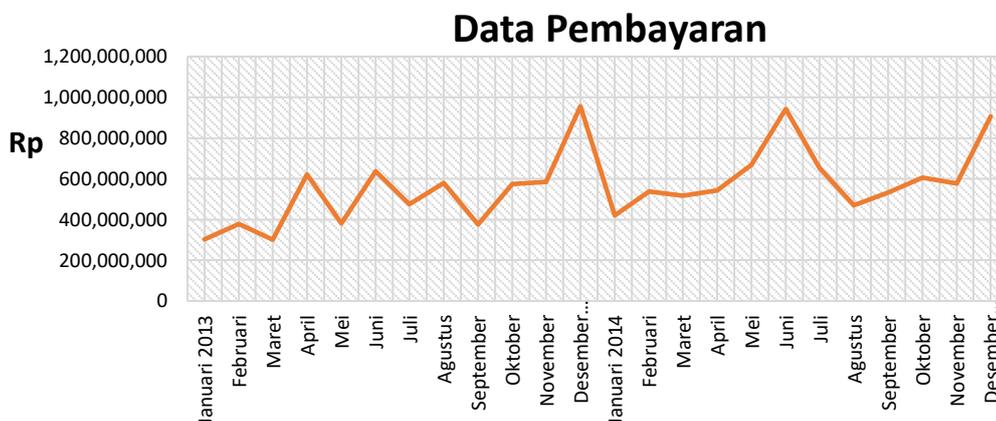
Teknik *data mining* adalah bagaimana menelusuri data yang ada untuk membangun sebuah model, kemudian menggunakan model tersebut agar dapat mengenali pola data yang lain yang tidak berada dalam basis data yang tersimpan. Kebutuhan untuk prediksi juga data memanfaatkan teknik ini. Dalam *data mining* pengelompokkan data juga bias dilakukan. Tujuannya adalah agar kita dapat

**ILKOM Jurnal Ilmiah Volume 9 Nomor 2 Agustus 2017**

mengetahui pola universal data-data yang ada. Semual hal tersebut bertujuan mendukung kegiatan operasional perusahaan sehingga tujuan akhir perusahaan diharapkan dapat tercapai[17]. Dalam perkembangan analisis data *time series*, banyak fenomena yang menarik dan sederhana merupakan fenomena yang *non-linear* (hubungan antara kejadian di masa lalu dan saat ini adalah non-linear). Sehingga pemodelan data *time series* yang *linear* tidaklah cukup dan sesuai untuk menangani kasus-kasus tersebut. Sebagai konsekuensinya, model-model *time series nonlinear* telah menjadi perhatian utama para peneliti prediksi *time series* pada beberapa tahun terakhir ini. Beberapa bentuk model *non-linear* telah dikembangkan dan diaplikasikan pada beberapa kasus *time series*, dan sebagai *overview*[18].

**3. Metode**

Pada penelitian ini sumber data di ambil dari data set PT. Multi Nabati Sulawesi Unit Maleo Kabupaten Pohuwato. Data yang dikumpulkan adalah data harian *time series* univariat. Jenis data berupa data pembayaran pembelian bahan baku kopra data yang diperoleh mulai dari tahun 2008-2014. Data set yang ada khusus untuk hari minggu tidak terjadi transaksi serta hari libur kalender setiap tahunnya. Data set dari variabel pembayaran memiliki 362 *record* yang berasal dari setiap relasi perusahaan. Dalam desain dan perancangan juga harus mengetahui pola data yang ada, data set termasuk dalam data set *linear* atau data set *nonlinear*. Pola data set pembayaran pembelian bahan baku kopra dapat dilihat pada sampel data pembayaran dibawah ini:



**Gambar2.** Grafik Pembayaran Kopra Tahun 2013-2014

Sesuai dengan gambar 2 data set pembayaran kopra, grafik tersebut menjelaskan bahwa data set tersebut termasuk dalam data set *nonlinear*. Data yang menghasilkan kelas tidak *linear* sering memanfaatkan pendekatan kernel.

Tahap preprocessing tahap pengolahan data univariat *time series* berupa numerik data harian. Data disusun menjadi data mingguan, agar lebih mudah proses pengolahannya, data di ubah dari data *ascending* menjadi *descending* proses ini dilakukan dengan cara memanfaatkan toolbar *sort & filter* yang ada pada *excel*. Kemudian data akan dinormalisasi. Pada ilmu database atau basis data, normalisasi berfungsi untuk menghindari terjadinya berbagai anomaly data dan tidak konsistensinya data. Normalisasi database bertujuan untuk memperoleh data yang memiliki ukuran lebih kecil untuk mewakili data asli dengan tidak kehilangan karakteristik dirinya[19]. Dengan persamaan sebagai berikut:

$$Normalisasi = \frac{(X-min)}{(max-min)} \tag{4}$$

Dimana:

*x* = Data

*Min* = Data Minimum

*Max* = Data Maksimum



Denormalisasi dataset adalah mengembalikan ukuran dataset yang sudah ternormalisasi untuk mengembalikan data asli. Denormalisasi diterapkan pada hasil eksperimen data testing yang berupa prediksi pembayaran pembelian bahan baku kopra. Persamaan dapat dilihat sebagai berikut:

$$\text{Denormalisasi} = Y (\text{max} - \text{min}) + \text{min} \quad (5)$$

Dimana:

**Y** = Hasil Keluaran Dari Pelatihan

**Min** = Data Minimum

**Max** = Data Maksimum

Dari hasil data normalisasi, data diubah univariat menjadi multivariate, kemudian data di ubah dari 1 sampai 7 periode. demikian halnya data training diubah menjadi multivariable independent, baik itu 1 periode sampai 7 periode memiliki masing-masing 1 variabel dependent. Sebagai sampel data 1 periode ( $x_{t-1} : x_t$ ), data 2 periode ( $x_{t-2}, x_{t-1} : x_t$ ), serta dengan data 7 periode ( $x_{t-7}, x_{t-6}, x_{t-5}, x_{t-4}, x_{t-3}, x_{t-2}, x_{t-1} : x_t$ ) demikian juga pada data testing. Proses ini dilakukan secara manual di excel. Pengubahan data jadi beberapa periode guna untuk mendapatkan model yang tepat buat memprediksi pembayaran pembelian bahan baku kopra.

*Time series* multivariat memodelkan peubah-peubah yang berkorelasi dan tercatat dari waktu ke waktu. Peubah tersebut dapat dinotasikan dalam tabel dibawah ini:

**Tabel 1.**Pola data Time Series Univariat ke Multivariate

Pettren	Input Lag	Output
1	$x_1, x_2, \dots, x_p$	$x_{p+1}$
2	$x_2, x_3, \dots, x_{p+1}$	$x_{p+1}$
3	$x_3, x_4, \dots, x_{p+2}$	$x_{p+1}$
...	...	
$m-p$	$x_{m-p}, x_{m-p+1}, x_{m-p+2}, x_{m-p+3} \dots, x_{m-1}$	$x_m$

Sesuai tabel 1 merupakan pola yang digunakan dalam mengubah data univariat ke multivariat, pola dan modelnya dapat dilihat seperti :

$$\text{model} : x_{m-p}, x_{m-p+1}, x_{m-p+2}, x_{m-p+3} \dots, x_{m-1} \quad (6)$$

Dimana:

$m-p$  = Nilai Pettren

$x_{m-p}$  = Input Lag

$x_m$  = Output/Target

Pemodelan dari data *time series* multivariat bertujuan untuk menentukan fungsi atau model yang tepat, dimana fungsi dari model tersebut dapat digunakan untuk memprediksi nilai-nilai yang akan datang dengan baik buat semua peubah didalam sistem. Hal ini dilakukan sebagai bahan perbandingan data mana yang dianggap baik digunakan untuk prediksi. Dimana setiap variabel *input* yang digunakan memiliki pola yang berbeda yaitu proses pembelajaran akan performa mempunyai jumlah masukan. Tujuan proses belajar yaitu untuk mempelajari pola data *time series* dan mendapatkan nilai parameter yang akan digunakan untuk prediksi data *time series*. Dalam proses pembelajaran *time series* multivariate data dibagi dua yaitu data masukan (Independen) dan data target (Dependen)[20]. Variabel-variabel data akan diseleksi dengan fitur seleksi *forward selection* yang bertujuan untuk memilih variabel yang memberikan informasi keakuratan prediksi agar performa algoritma dapat dioptimalkan. *Forward selection* tujuan kerjanya membangun model simulai dengan tidak ada variabel dalam model dan menambahkan variabel yang berguna satu persatu. Proses data yang ditraining dikerjakan secara *step-by-step* diawali mulai dari 1 variabel sampai dengan jumlah variabel yang menghasilkan performa akurasi paling baik.

#### 4. Eksperimen Dan Pengujian

Eksperimen dilakukan dengan beberapa tahapan. Pada tahap 1 preprocessing data yang bertujuan mengubah data dari harian menjadi mingguan. Tahap 2 data diubah dari *ascending* ke *descending*. Tahap 3 melakukan normalisasi data. Tahap 4 data diubah dari univariat ke multivariat.

**ILKOM Jurnal Ilmiah Volume 9 Nomor 2 Agustus 2017**

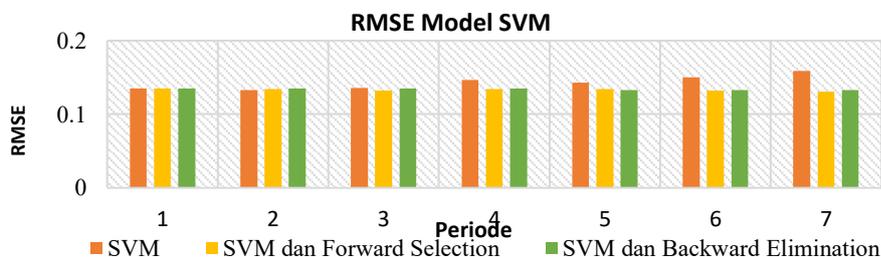
Tahap 5 menentukan parameter SVM dan *forward selection*. Dalam penentuan parameter SVM dilakukan beberapa pengujian seperti penentuan jumlah variabel *input independent* atau variabel periode *xt-i* dan pemilihan *type kernel*, percobaan ini digunakan untuk menemukan model terbaik dengan melihat tingkat nilai *root mean square error* yang terkecil. Setelah melewati tahapan demi tahapan sampai pada penentuan parameter SVM dan *Forward Selection* serta *Backward Elimination* membandingkan BPNN dan *Forward Selection* serta *Backward Elimination*, dilanjutkan pada tahap 6 yaitu pengaplikasian model yang terbaik yang dihasilkan algoritma SVM terhadap data testing untuk melakukan peramalan. Proses eksperimen digunakan beberapa sampel data set dalam melakukan uji coba, kemudian dilanjutkan dengan penetapan parameter sebelum memulai proses uji coba nilai parameter yang digunakan dalam proses uji coba sama dengan nilai training yaitu nilai variabel input atau variabel periode *xt-i* dari 1 – 7, *number of validation* 10 dengan *type kernel polynomial* dan *C* (cost) kemudian dilakukan proses testing untuk mengetahui hasil *root mean square error*.

**Tab2.** Nilai RMSE pada SVM, SVM dan *Feature Selection*

Nilai Variabel Periode	Number of Validation	Type Kernel	RMSE SVM	RMSE Forward Selection	RMSE Backward elimination
1	10	polynomial	0,135	0,135	0,135
2	10	polynomial	<b>0,133</b>	0,134	0,135
3	10	polynomial	0,136	0,132	0,135
4	10	polynomial	0,147	0,134	0,135
5	10	polynomial	0,143	0,134	<b>0,133</b>
6	10	polynomial	0,150	0,132	<b>0,133</b>
7	10	polynomial	0,159	<b>0,131</b>	<b>0,133</b>

Sesuai dengan tabel 2 adalah tabel rangkuman hasil eksperimen uji coba pembayaran kopra dengan pemilihan model menggunakan algoritma *support vector machine* (SVM), SVM dan *Forward Selection*, SVM dan *Backward Elimination* mulai dari 1 sampai 7 variabel periode untuk data pembayaran kopra menggunakan *number of validation* 10 dan *type kernel polynomial* yang diambil berdasarkan tingkat nilai *root mean square error* (RMSE) paling terkecil. Maka ditemukannya model terbaik yang dilihat berdasarkan tingkat nilai *error* terkecil algoritma SVM pada periode 2 yang bernilai 0,133, algoritma SVM dan *forward selection* pada periode 7 yang bernilai 0,131, sedangkan algoritma SVM dan *backward elimination* pada periode 5,6, dan 7 yang bernilai 0,133.

Sesuai hasil eksperimen pengolahan model *forward selection* menampilkan bahwa nilai pada *attribute weights* menampilkan nilai pada variabel *xt-1* dan *xt-6* adalah 1 dan nilai pada variabel *xt-2*, *xt-3*, *xt-4*, *xt-5* dan *xt-7* adalah 0, dengan demikian variabel yang dianggap signifikan adalah variabel *xt-1* dan variabel *xt-6*. Sesuai hasil eksperimen pengolahan model *backward elimination* periode 5 menampilkan bahwa nilai pada *attribute weights* menampilkan nilai pada variabel *xt-1* dan *xt-2* adalah 1 dan nilai pada variabel *xt-3*, *xt-4* dan *xt-5* adalah 0, dengan demikian variabel yang dianggap signifikan adalah variabel *xt-1* dan variabel *xt-2*, periode 6 menampilkan bahwa nilai pada *attribute weights* menampilkan nilai pada variabel *xt-1* dan *xt-6* adalah 1 dan nilai pada variabel *xt-2*, *xt-3*, *xt-4* dan *xt-5* adalah 0, dengan demikian variabel yang dianggap signifikan adalah variabel *xt-1* dan variabel *xt-6*, dan periode 7 menampilkan bahwa nilai pada *attribute weights* menampilkan nilai pada variabel *xt-1* dan *xt-6* adalah 1 dan nilai pada variabel *xt-2*, *xt-3*, *xt-4*, *xt-5* dan *xt-7* adalah 0, dengan demikian variabel yang dianggap signifikan adalah variabel *xt-1* dan variabel *xt-6*.



**Gambar 3.** Grafik RMSE Model SVM, SVM dan *Feature Selection*

Sesuai dengan gambar 3 yaitu grafik perbandingan model yang paling baik untuk data pembayaran kopra, algoritma SVM, SVM dan *forward selection* serta SVM dan *backward elimination* menggambarkan bahwa model terbaik algoritma SVM terdapat pada variabel periode 2, dengan *number of validation* 10 dan *type kernel polynomial* yaitu tingkat RMSE sebesar 0,133. Pada model

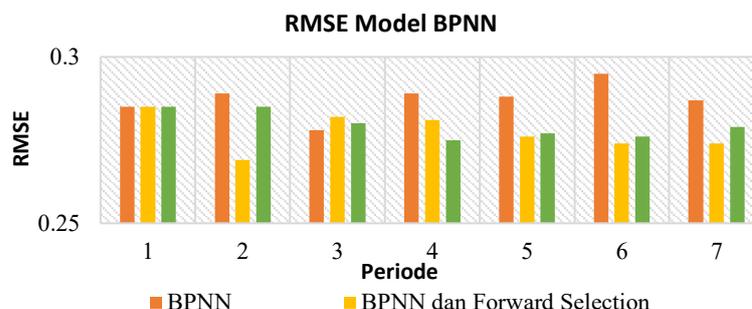


**ILKOM Jurnal Ilmiah Volume 9 Nomor 2 Agustus 2017**

SVM dan *forward selection* terdapat pada variabel periode 7, dengan *number of validation* 10 dan *type kernel polynomial* pada *forward selection* yaitu tingkat RMSE sebesar 0,131, sedangkan pada *backward elimination* terdapat kesamaan hasil RMSE, variabel periode 5, 6 dan 7, dengan *number of validation* 10 *type kernel polynomial* pada yaitu tingkat RMSE 0,133.

**4.1. Perbandingan Model**

Pada penelitian ini juga melakukan eksperimen menggunakan model BPNN, BPNN dan *Forward Selection* serta BPNN dan *Backward Elimination*. Dimana hasil perbandingan RMSE antar model BPNN, BPNN dan *Feature Selection* dapat dilihat pada gambar 3.



**Gambar 4.** Grafik RMSE Model BPNN, BPNN dan *Feature Selection*

Sesuai dengan gambar 4 yaitu merupakan grafik perbandingan model BPNN, BPNN dan *Forward Selection* serta BPNN dan *Bacward Elimination* menggambarkan bahwa model terbaik pada variabel periode 2 dengan *feature selection* menggunakan *Forward Selection* dengan tingkat nilai RMSE 0,269.

Hasil dari perbandingan prediksi RMSE menggunakan algoritma SVM dan *Feature Selection* dan BPNN dan *Featute Selection* dapat dilihat pada table berikut:

**Tabel3.** Nilai RMSE pada SVM dan *Feature Selection*, BPNN dan *Feature Selection*

Algoritma	Nilai Variabel Periode	RMSE
SVM	2	0,133
<b>SVM Forward Selection</b>	<b>7</b>	<b>0,131</b>
SVM Bacward Elimination	5	0,133
	6	0,133
	7	0,133
BPNN	3	0,278
BPNN Forward Selection	2	0,269
BPNN Bacward Elimination	4	0,275

Sesuai dengan tabel3 menunjukan bahwa model yang tepat digunakan untuk melakukan peramalan pembayaran pembelian bahan baku kopra yaitu pada model algoritma SVM dan *Forward Selection* dikarenakan tingkat nilai RMSE terkecil.

**5. Kesimpulan**

Sesuai hasil eksperimen yang telah dilakukan untuk prediksi pembayaran pembelian bahan baku kopra dengan menerapkan algoritma *Support Vector Machine* (SVM) dan *Forward Selection* telah berhasil dilakukan. Dari hasil eksperimen yang dilakukan menjelaskan bahwa *feature selection* yaitu *forward selection* adalah model yang terbaik dalam menyeleksi variabel yang signifikan jika dibandingkan dengan *backward elimination*. Algoritma *Support Vector Machine* dan *Forward Selection* telah memberikan performa kinerja yang lebih baik dibandingkan dengan algoritma SVM, SVM dan *Backward Elimination* dan BPNN.

**Daftar Pustaka**

[1]. Nurwarsito, H. Desember 2009. Sistem Transaksi Pembayaran *Food Court* Dengan Teknologi E-Card, *Jurnal EECCIS* Vol. III, No. 2.  
[2] Pakasi, Caroline, B.D. Juni 2013. Pengembangan Kelapa Sebagai Komoditi Unggulan Daerah Sulawesi Utara dengan Pendekatan Klaster Industri, Seminar Nasional : Menggagas



- Kebangkitan Komoditas unggulan Lokal Pertanian dan Kelautan Fakultas Pertanian Universitas Trunojoyo Madura, Universitas Sam Ratulangi Manado.
- [3]. Sularno, A. 2014. Prediksi Nilai Saham Menggunakan Pemograman Genetika Dan Pemograman Ekspresi Gen, Universitas Gunadarma Depok. Indonesia.
- [4]. Widodo, A, Budi, I, dan Aji, R.F. 2012. Prediksi topic penelitian menggunakan kombinasi antar *Supprot Vector Regression* dan Kurva Logistik, Universitas Indonesia, Seminar Nasioanal Aplikasi Teknologi Informasi, ISSN:1907-5022, Yogyakarta.
- [5]. Prasetyo, Eko. 2012.*Data mining* Konsep dan Aplikasi menggunakan Matlab, *ANDI*, Yogyakarta, 177.
- [6]. Y Liu, YF Zheng. 2012. *FS\_SFS:Anovel feature selection method for support vector machines*, *The Ohio State University, Columbus OH 43210, USA*. Pattern recognition.
- [7]. Neneng, S. 2009. Seleksi Variabel dalam Analisis Regresi Multivariat Multiple, Stap Jurusan Statistika FMIPA UNPAD, Seminar Nasional dan Pendidikan Matematika, ISBN: 978-979-16353-3-2.
- [8]. F.G, Blanchet, P, Legendre, and D. Borcard. 2008. *Forward Selection Of Explanatory Variables*. Ecology, Vol. 89. No. 9, - Eco Soc America.
- [9]. Intan Martina Md Ghani dan Sabri Ahmad. 2011.*Comparison Methods of Multiple Linear Regression in Fish Landing*, *Australian Journal of Basic and Applied Sciences*, 5(1): 25-30.
- [10]. Nugroho, A.S, Witarto, A.B, Handoko, D. 2003.*Supprot Vector Machine* Teori dan Aplikasinya dalam Bioinformatika.
- [11]. M, Hofmann. 2007. *Support Vector Machines — Kernels and the Kernel Trick*.
- [12]. Prasetyo Eko. 2012. Data Mining Konsep dan Aplikasi menggunakan Matlab, *ANDI*, Yogyakarta, 127-130.
- [13]. Prasetyo Eko. 2012. *Data Mining* Konsep dan Aplikasi Menggunakan Matlab, *ANDI*, Yogyakarta, 72-73.
- [14]. Raharjo, J.S.D. Juni 2013. Model *Artificial Neural Network* Berbasis *Particle Swarm Optimization* untuk Prediksi Laju Inflasi, Sekolah Tinggi Manajemen Informatika dan Komputer Eresha Jakarta, *Jurnal Sistem Komputer*, Vol. 3, No. 1, ISSN: 2087-4685.
- [15]. Fikri, A. 2013. Penerapan *Data Mining* Untuk Mengetahui Tingkat Kekuatan Beton Yang Dihasilkan Dengan Metode Estimasi Menggunakan Linear Regression, Universitas Dian Nuswantoro Semarang.
- [16]. Alda Raharja dan Wiwik Anggraeni, S.Si, M.Kom dan Retno Aulia Vinarti, S.Kom. 2010. Menerapkan Metode *exponential Smoothing* untuk Peramalan penggunaan waktu telpon di Pt.telkomsel divre3, *SISFO-Jurnal Sistem Informasi*.
- [17]. Prasetyo Eko.2012.*Data Mining* Konsep dan Aplikasi menggunakan matlab, *ANDI* Yogyakarta, 2.
- [18]. Suhartono. 2007.*Feedforward Neural Networks Untuk Pemodelan Runtun Waktu*, Universitas Gadjah Mada Yogyakarta, 25 September.
- [19]. Indrabayu, Harun, N dan Pallu, M.S, Achmad, A, dan L, F,I. 2012. Prediksi Curah Hujan dengan Jaringan Saraf Tiruan, Universitas Hasanuddin, ISBN: 978-979-127255-0-6, Vol. 6, Makassar Desember.
- [20]. Purwanto, C. Eswaran dan Logeswaran, R. 2011, *Improved Adaptive Neuro-Fazzy Inference System for HIV/AIDS time series Prediction*, A. Abd Manaf et al. (Eds): ICIEIS 2011, Part III, CCIS 253, pp. 1-13.