

## Perbaikan Peramalan Produksi Padi di Kabupaten Kendal dengan Menggunakan Metode Support Vector Machine (SVM)

Ayu Andita<sup>1\*</sup>, Wellie Sulistijanti<sup>2</sup>

<sup>1,2</sup> Statistika, Akademi Statistika(AIS) Muhammadiyah Semarang  
Email: ayuandita2014@gmail.com

### Abstrak

**Keywords:**  
Peramalan  
Produksi Padi;  
Seasonal  
Autoregressive  
Integrated Moving  
Average;  
Support Vektor  
Machine

Sektor pertanian memegang peranan penting bagi perekonomian daerah sebagai peningkatan produksi bahan pangan khususnya bahan makanan pokok bagi kehidupan manusia, tentunya masyarakat di Kabupaten Kendal. Pada Tahun 2015, produksi padi di Kabupaten Kendal menempati peringkat 18 se-Jawa Tengah, Dinas Pertanian Kendal sangat memperhatikan perkembangan produksi padi sehingga memerlukan perencanaan dalam peramalan yang harus dilandasi dengan kekuatan model dan parameter yang signifikan. Penelitian ini menggunakan data dari bulan Januari 2013- Januari 2016, 70% dari 48 data sebagai data training dan 30% data testing. Peramalan yang baik memiliki nilai Mean Square Error (MSE) yang kecil. Peramalan produksi padi dengan metode Seasonal Autoregressive Integrated Moving Average (SARIMA) diperoleh MSE training sebesar 0.043918 dan MSE testing 77.118.361,62, terlihat bahwa nilai MSE antara keduanya sangat jauh berbeda. Dengan metode Support Vektor Machine (SVM) diperoleh MSE training sebesar 0,14 dan MSE testing sebesar 0,57. Terlihat bahwa nilai MSE yang dihasilkan sangat dekat tidak jauh berbeda dengan keduanya. Inilah kelebihan metode yang telah diusulkan oleh peneliti dengan menggunakan Metode SVM merupakan metode yang baik untuk meramalkan produksi padi di Kabupaten Kendal, karena nilai MSE training dan MSE testing yang kecil, tidak memerhatikan parameter yang signifikan dan dapat menanggapi permasalahan linier ataupun non linier tanpa memerhatikan pola data.

### 1. PENDAHULUAN

Kabupaten Kendal mempunyai wilayah agraris, hal ini ditunjukkan dengan besarnya luas lahan untuk hal pertanian. Kondisi geografis dipergunakan untuk tanah sawah 25,93 persen, tegalan 20,89 persen, hutan 17,03 persen, perkebunan 7,85 persen, lahan bukan pertanian 22,7 persen dan lain-lain sebesar 5,93 persen (BPS-Statistics of Kendal Regency, 2017). Berdasarkan presentase luas lahan diatas menunjukkan bahwa mayoritas lahan sawah sebesar 25,93 persen digunakan untuk pertanian khususnya ditanami padi yang merupakan sumber tanaman pangan bagi manusia sebagai makanan pokok. Tidak bisa dipungkiri bahwa pangan merupakan salah satu kebutuhan paling penting dan yang pertama kalinya harus dicukupi oleh setiap manusia. namun, hal tersebut sama sekali bukan berarti bahwa manusia diciptakan dan hidup hanya untuk makan, melainkan manusia secara bijaksana harus makan agar tetap bisa bertahan hidup dan melakukan aktivitas secara optimal (Darmawan, 2004). Aktivitas seorang petani secara optimal akan menghasilkan produksi padi yang tinggi. Padi yang telah ditanam oleh petani terdapat dua macam padi yaitu padi sawah dan padi gogo, yang menjadi perhatian pada padi sawah dengan melihat perkembangannya, produksi padi yang ada pada kabupaten Kendal.

Menurut data dari Badan Pusat Statistika Jawa Tengah bahwa hasil produksi padi pada tahun 2015 di Kabupaten Kendal sebesar 287.925 ton, yang mana menempati peringkat 18

dari 29 kabupaten di Jawa Tengah, hasil produksi padi yang tertinggi Sebesar 28.959 ton diperoleh dari kecamatan Boja, namun, pada tahun 2016 mengalami penurunan sebesar 4.808 ton (Dinas Pertanian, 2016). Untuk memberikan keseimbangan investasi di Kabupaten Kendal, maka sektor pertanian diharapkan menghasilkan produksi padi yang meningkat agar tidak berdampak pada pendapatan Petani. Karena produksi padi merupakan hasil kali dari luas panen dan produktivitas, dapat dikatakan bahwa jika produksi naik maka harga beras akan turun sebaliknya jika produksi turun maka harga beras akan naik. Pada bulan Mei tahun 2017, Mirna Annisa selaku Bupati Kendal memberikan kabar kepada para petani, hasil panen padi mereka akan dibeli oleh Pemkab Kendal lebih tinggi dari Bulog maupun Tengkulak. Mendengar hal tersebut Bupati sangat mendukung terhadap peningkatan Produksi padi di Kabupaten Kendal. Maka, tindakan peramalan produksi padi sangat penting bagi Dinas Pertanian.

Pada umumnya produksi padi mengandung pola musiman yang bergerak pada beberapa periode setiap tahun, adapun beberapa metode peramalan sebagai penanganan dalam hal pola musiman, yaitu metode *Seasonal Autoregressive Integrated Moving Average (SARIMA)*. SARIMA adalah metode *Box-Jenkins* untuk mencari sebuah pola musiman yang cocok untuk sekelompok data Metode ini memanfaatkan data masa lalu dan data sekarang untuk mendapatkan peramalan di periode mendatang. Namun, metode ini memiliki kelemahan dalam uji parameter harus signifikan dan nilai *Mean Square Error (MSE)* antara data training dan testing berbeda jauh. Oleh karena itu peneliti mengusulkan memberikan perbaikan untuk meramalkan produksi padi dengan menggunakan metode *Support Vector Machine (SVM)* dimana pada metode ini mempunyai kemampuan menghasilkan tingkat keakuratan yang cukup baik dan mampu menyelesaikan permasalahan data linier ataupun non linier dan juga mampu memecahkan data dengan sampel kecil (Fei & Sun, 2008).

Untuk merujuk pada “Perbaikan Peramalan Produksi Padi di Kabupaten Kendal dengan Menggunakan Metode Support Vector Machine (SVM)”. Maka dari metode SARIMA yang telah ditulis oleh Agus Supriatna, dkk, dengan judul “Prediksi Wisatawan Mancanegara Ke Jawa Barat Melalui Pintu Masuk Bandara Husein Sastranegara dan Pelabuhan Muarajati Menggunakan Metode SARIMA” telah mengaplikasikan metode tersebut, dimana telah banyak dilakukan diberbagai penelitian, karena merupakan salah satu metode time series univariate yang baik dalam menghasilkan prediksi jangka pendek. Untuk tindak lanjutnya dalam perbaikan peramalan pada penelitian ini, sebelumnya telah diaplikasikan oleh menggunakan metode SVM oleh Imelda A.Muis, Muhammad Affandes, M.T pada tahun 2015 telah mengimplementasi tentang “Penerapan Metode *Support Vector Machine (SVM)* Menggunakan *Kernel Radial Basis Function (RBF)* Pada Klasifikasi *Tweet*” hasil yang didapat dalam penelitiannya adalah keakuratan peramalan dengan nilai MAPE yang tergolong baik, dan *Grid-search* sebagai optimasi parameter untuk mencari solusi model yang terbaik.

Dari uraian diatas, rumusan masalah yang akan diselesaikan dalam penelitian ini adalah bagaimana hasil peramalan produksi padi di Kabupaten Kendal dengan menggunakan metode *Support Vector Machine (SVM)* sebagai perbaikan peramalan dari Metode *Autoregressive Integrated Moving Average (SARIMA)* dengan minimalisasi nilai *Mean Square Error (MSE)*.

Adapun yang menjadi tujuan penelitian ini adalah untuk mengetahui hasil ramalan produksi padi di Kabupaten Kendal dengan menggunakan metode *Autoregressive Integrated Moving Average (SARIMA)* serta hasil perbaikan peramalan menggunakan metode *Support Vector Machine (SVM)*.

## 2. METODE

Metode penelitian yang digunakan pada penelitian ini adalah metode peramalan produksi padi di Kabupaten Kendal dengan menggunakan metode *Seasonal Autoregressive Integrated Moving Average (SARIMA)* dan *Support Vector Machine (SVM)*. Data yang digunakan berupa data kuantitatif, yang merupakan data sekunder produksi padi dari

bulan Januari 2013 sampai bulan Desember 2016 yang diperoleh dari Dinas Pertanian, Peternakan, Perkebunan dan Kehutanan. Data yang diperoleh sejumlah 48 periode. Penelitian ini dalam menganalisis menggunakan Program Minitab16 dan aplikasi R.

### 2.1 *Seasonal Autoregressive Integrated Moving Average (SARIMA)*

SARIMA adalah salah satu metode deret waktu yang terdiri dari pola musiman atau *Seasonal*, Autoregressive (AR), Moving Average (MA) dan *Integrated*. Metode SARIMA ditulis dalam bentuk (p,d,q) (P,D,Q)<sup>s</sup> Orde p merupakan komponen Autoregressive yang digunakan untuk memodelkan autokorelasi yang terdapat pada deret waktu dengan melakukan regresi pada variabel lag sebesar p, orde d menyatakan orde differencing untuk membuat data yang tidak stasioner menjadi stasioner, orde q merupakan orde Moving Average untuk memodelkan lagged error sebanyak q, orde P merupakan orde Autoregressive musiman, D orde differencing pada periode musiman, dan Q adalah orde Moving Average musiman (Supriatna, Subartini, & Hertini, 2017)

Persamaan model SARIMA (*Seasonal Autoregressive Integrated Moving Average*) atau ARIMA musiman (p,d,q) (P,D,Q) dengan rumus umum:

$$\hat{\phi}_p(B)\hat{\phi}_p(B^S)Z_t = \theta_q(B)\phi_Q(B^S)e_t$$

(Wei, 1990)

Dimana:

$$\begin{aligned} Z_t &= (1 - B)^d(1 - B^S)^D Y_t^* \\ \hat{\phi}_p(B) &= (1 - \hat{\phi}_1 B - \hat{\phi}_2 B^2 - \dots - \hat{\phi}_p B^p) \\ \hat{\phi}_p(B^S) &= (1 - \hat{\phi}_1 B^S - \hat{\phi}_2 B^{2S} - \dots - \hat{\phi}_p B^{pS}) \\ \theta_q(B) &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \\ \phi_Q(B^S) &= (1 - \phi_1 B^S - \phi_2 B^{2S} - \dots - \phi_Q B^{pS}) \end{aligned}$$

Dengan:

$$\begin{aligned} Z_t &= \text{nilai variabel } Z \text{ pada periode ke } -t \\ e_t &= \text{nilai error periode ke } -t \\ \hat{\phi}_p &= \text{paramete AR non musiman} \\ \hat{\phi}_p &= \text{parameter AR musiman} \\ \theta_q &= \text{parameter MA non musiman} \\ \phi_Q &= \text{parameter MA musiman} \\ S &= \text{jumlah periode permusim} \\ D &= \text{ordo pembeda musiman} \\ Y_t^* &= \text{data yang ditransformasi} \end{aligned}$$

Adapun tahap umum yang dilakukan untuk peramalan menggunakan metode *Seasonal Autoregressive Integrated Moving Average (SARIMA)*, yaitu:

1. Stationeritas, dalam proses peramalan, harus memperhatikan pola data, pada metode ini pola data harus mengandung musiman yang dapat dilihat pada setiap periode yang sama ada pendekatan nilai. Untuk pengujian kestasioneran data dapat diuji melalui dua cara, yaitu menggunakan *Box-Cox Transformation* untuk stasioner variandan *Augmented Dickey Fuller* untuk stasioner rata-rata.
2. Estimasi parameter, setelah data stasioner akan dibuat model sementara dengan mengidentifikasi plot *Autocorrelation Function (ACF)* dan *Partial Autocorrelation Function (PACF)* untuk menentukan orde pada model. Langkah selanjutnya lakukan estimasi parameter-parameter AR, MA, musiman dan non-musiman dan uji signifikansi dari parameternya.

3. Diagnostik model, pemeriksaan diagnostik dilakukan untuk mengecek kelayakan dari model yang sudah dipilih atau proses *white noise* dengan melihat uji Ljung-box dan uji kenormalan residual dengan uji *Kolmogorov-smirnov*.

Pada langkah pengujian ini dilakukan evaluasi model dan peramalan, jika terdapat beberapa model yang memenuhi asumsi dari kedua uji yaitu *white noise* dan uji kenormalan residual maka, dapat dilakukan seleksi dengan mendeteksi nilai *Mean Square Error* (MSE) dipilih yang terkecil untuk dijadikan model peramalan yang merupakan seni dan ilmu untuk memperkirakan kejadian di masa depan. Tujuan dari peramalan adalah menghasilkan prediksi dengan kesalahan yang minimum. Data yang digunakan untuk peramalan merupakan data deret waktu yang beruntun.

## 2.2 Support Vector Machine (SVM)

Support Vector Machine (SVM) pertama kali diperkenalkan oleh Vapnik pada tahun 1992 sebagai rangkaian harmonis konsep-konsep unggulan dalam bidang pattern recognition. SVM adalah metode learning machine yang bekerja atas prinsip Structural Risk Minimization (SRM) dengan tujuan menemukan hyperplane terbaik yang memisahkan dua buah class pada input space (Nugroho, Witarto, & Handoko, 2003). Sebagai metode pembelajaran yang diawasi menghasilkan fungsi pemetaan input-output dari serangkaian data pelatihan berlabel (Wang (Ed.), 2005). Support vector machine (SVM) juga menerapkan prinsip minimalisasi risiko struktural di tempat minimisasi minimal pengalaman, yang membuatnya memiliki kemampuan generalisasi yang sangat baik dalam situasi sampel kecil (Fei & Sun, 2008). Berikut langkah-langkah peramalan dengan menggunakan metode ini:

1. Pre-Processing data, sebelum proses pengolahan data hendaknya yang perlu diperhatikan adalah tahap pertama pengumpulan data yang akan digunakan dalam tugas akhir ini. Selanjutnya adalah pemeriksaan dan penanganan data, apakah ada data yang *missing* atau tidak, uji normalitas dengan menggunakan, kemudian pembagian data yang meliputi data pelatihan (*training*) dan data pengujian (*testing*) dengan presentase 70:30 dari seluruh data berjumlah  $n$ . Lalu data disimpan dalam format dan data siap diolah.
2. Pemodelan dengan SVM, pada tahap ini mulai dilakukan *training* SVM, Hal yang terlebih dahulu dilakukan yaitu dengan menentukan tipe kernel dan nilai parameter. Jika model terbaik pada data telah terpilih berdasarkan hasil algoritma *grid-search* maka bisa untuk dilakukan peramalan. Tahapan pemodelan SVM melalui dua cara, meliputi; pengolahan data input, dalam tahapan ini yang perlu dilakukan yaitu *transformasi* data jika data tidak memenuhi asumsi normalitas. Kemudian data yang sudah di *transformasi* disimpan dalam format csv dan siap untuk diimplementasikan pada aplikasi R. Selanjutnya membangun model SVM, dalam pembentukan model yang harus dilakukan penambahan *package* yaitu (e1071). untuk membentuk model awal perlu dilakukan pemanggilan *library* (e1071). Selanjutnya mulai membuat model SVM dari data *training* yang telah ditentukan sebelumnya. Dari data tersebut sistem akan menampilkan nilai setiap prediksi sebagai bentuk awal (*default*) dari model SVM.
3. Menentukan tipe Kernel, pada penentuan kernel, data ini yang menggunakan pola non-linier dimana, dilakukan *mapping* ruang input dari data *training* ke *feature space* dimensi yang lebih tinggi. Fungsi apapun yang dapat memenuhi *Mercer's condition* dapat digunakan sebagai fungsi kernel. Pada fungsi kernel, akan ditentukan nilai parameter seperti nilai  $C$  (*cost*) dan ( $\gamma$ ). Apabila mengimplmentasi dengan fungsi kernel radial, maka fungsi kernel untuk SVM, sebagai berikut (Nello Cristianini, 2002)

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$$

4. Penentuan nilai parameter, untuk penentuan *ranges* nilai parameter dari kernel yang dipilih sebelumnya. Penentuan nilai parameter sebagai *epsilon*, *C (cost)* dan  $\gamma$  (*gamma*) dilakukan dengan implementasi algoritma *grid-search*. *Grid-search* akan melatih banyak pasangan model dari *range* nilai yang telah ditentukan
- Evaluasi Hasil Peramalan, sebuah peramalan harus memiliki nilai akurasi baik dalam penelitian ini untuk menentukan hasil peramalan yang baik dengan menggunakan nilai *Mean Square Error (MSE)* terkecil dimana, menghasilkan error yang menunjukkan perbedaan dari hasil prediksi dan data estimasi, Perbedaan yang muncul diakibatkan oleh keacakan pada data atau kurang akuratnya estimasi yang diperoleh. Rumus MSE secara umum dapat dituliskan :

$$MSE = \frac{\sum_{t=1}^n (x_t - f_t)^2}{n}$$

Dimana :

$n$  = jumlah Sampel

$x_t$  = nilai Aktual Indeks pada periode ke-t

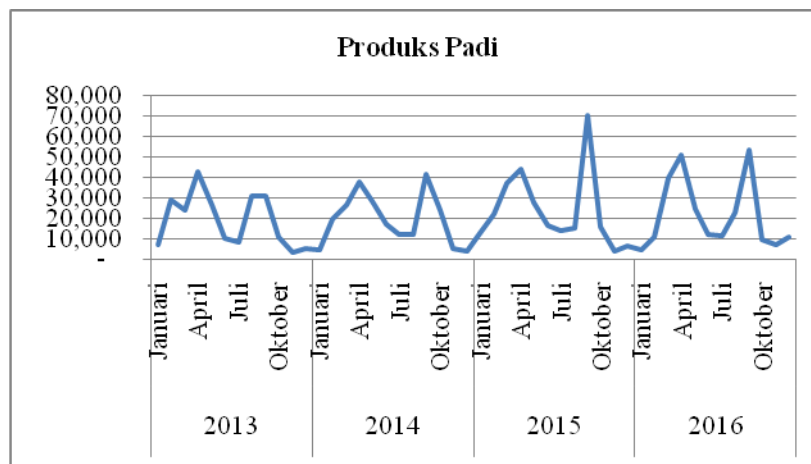
$f_t$  = nilai Prediksi Indeks pada periode ke-t

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Analisis deskriptif

Analisis yang pertama dilakukan analisis deskriptif, untuk mengetahui gambaran umum data yang diperoleh yaitu mengenai hasil produksi padi tahun 2013 sampai tahun 2016. Dari hasil analisis deskriptif didapatkan hasil *time series plot* seperti di bawah ini.

Tabel 3. 1 Hasil Produksi Padi tahun 2013 sampai 2016



Berdasarkan tabel 3.1 dapat diketahui bahwa hasil produksi sawah yang paling tinggi pada bulan September tahun 2015 sebesar 70.444 ton, dan terendah dengan hasil produksi sebesar 3.478 pada bulan November tahun 2013.


#### 3.2 Analisis time series

##### 1. Seasonal Autoregressive Integrated Moving Average (SARIMA)

Dalam penelitian ini penulis menggunakan metode SARIMA, dimana langkah-langkah dalam metode ini, sebagai berikut:

- Identifikasi model

1) Plot data




Gambar 3. 1 Time Series Plot Produksi Padi

Pada Gambar 3.1 diatas menggambarkan plot data untuk melihat kestasioneran data awal, mengetahui ada tidaknya unsur trend, siklis atau musiman. Pada bulan Maret dan Mei mengandung unsur musiman karena terjadi perubahan hasil produksi yang hampir sama secara berulang pada setiap periodenya.

2) Stasioneritas

Untuk mengetahui data tersebut stasioner atau tidaknya dalam hal varians menggunakan uji Box-cox transformation sedangkan untuk uji stasioner data dalam hal rata-rata, menggunakan uji Augmented Dickey Fuller (ADF). Pada pengujian ini Peneliti menggunakan data 36 dari 48 untuk data *training*, Berikut ini hasil Box-Cox Transformation dari data bulanan produksi padi tahun 2013 sampai 2016:



Sumber: Output Minitab 16

Gambar 3. 2 Box-cox transformation

Pada gambar 3.2 telah didapatkan hasil *transformation* yang sebelumnya telah diuji dengan nilai estimasi/*Rounded Value* = 0,00 , maka harus dilakukan transformasi  $\ln Z_t$  dari data tersebut, sehingga setelah di *transformation* dapat disimpulkan data produksi padi telah stasioner dalam varians. Selanjutnya dilakukan pengujian stasioneritas dalam rata-rata menggunakan data yang sudah ditransformasi

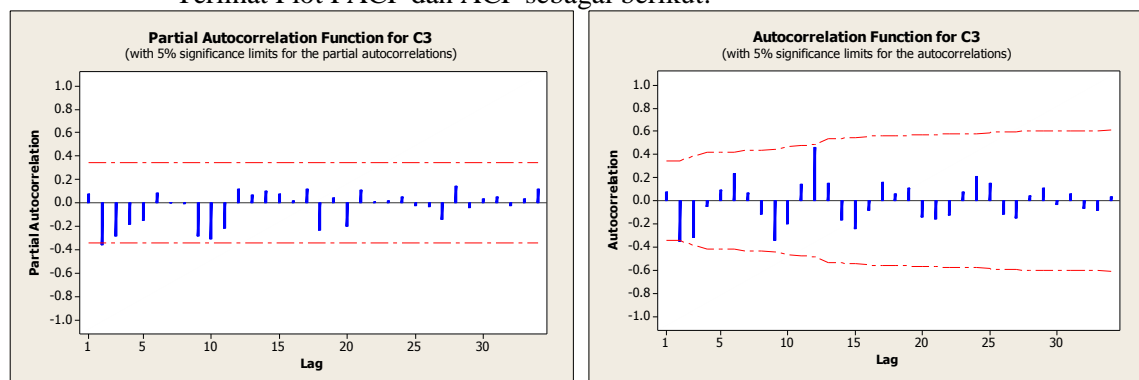
dengan menggunakan *Eviews* 8, dan diperoleh hasil uji *Augmented Dickey Fuller* sebagai berikut:

Tabel 3. 2 ADF Unit Root Test  
Uji akar unit

Test critical values	t-Statistic	Prob
-2.948404	-4.546754	0.0009

Berdasarkan tabel di atas mengindikasikan bahwa nilai mutlak untuk *Critical Value* (pilih alpha 5%) lebih besar dari nilai mutlak *t ADF Test Statistic* maka data tersebut tidak stasioner dalam mean, maka dilakukan *differencing*. Setelah data di *differencing*.

Terlihat Plot PACF dan ACF sebagai berikut:



Gambar 3. 3 Plot PACF dan ACF setelah differencing

Bahwa diketahui hasil *differencing* plot diatas adalah untuk model musimannya, berikut ada model sementara beserta kombinasi:

SARIMA (2,0,1)(1,1,1)<sup>12</sup>, (2,0,1)(0,1,1)<sup>12</sup>, (2,0,1)(1,1,0)<sup>12</sup>, (1,0,1)(1,1,1)<sup>12</sup>, (1,0,1)(0,1,1)<sup>12</sup>, (1,0,1)(1,1,0)<sup>12</sup>, (2,0,1)(1,1,1)<sup>12</sup>, (2,0,1)(0,1,1)<sup>12</sup>, (2,0,1)(1,1,0)<sup>12</sup>, (1,1,0)(1,1,1)<sup>12</sup>, (1,1,0)(0,1,1)<sup>12</sup>, (1,1,0)(1,1,0)<sup>12</sup>

### 3) Estimasi Parameter

Untuk syarat signifikan parameter dilihat dari P-value < 5% maka dikatakan signifikan parameter. Bahwa ada 2 model yang signifikan, untuk melihat keteranganya dapat dilihat pada Tabel 3.4.

Tabel 3. 3 Estimasi Parameter Model SARIMA

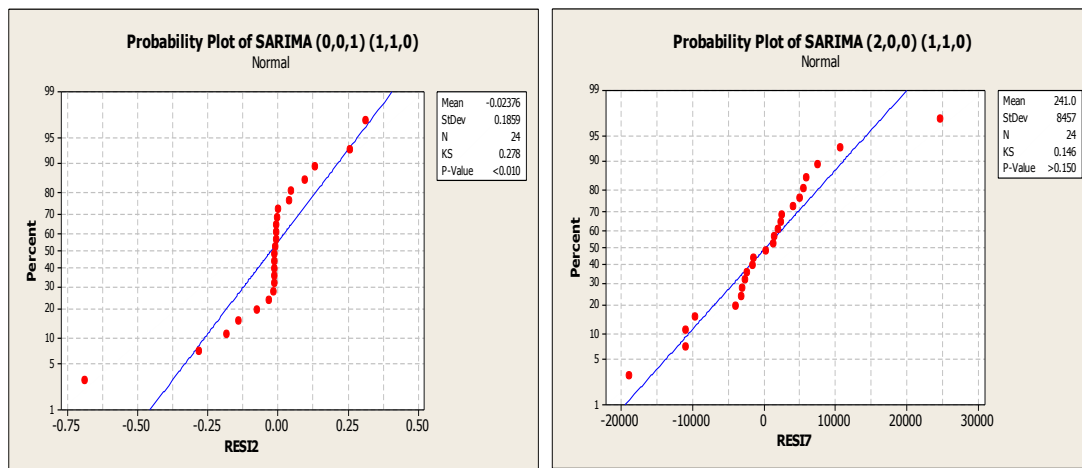
Model	Parameter	P-value	Keterangan
SARIMA (0,1,1)	SAR	0.000	Signifikan
	(1,0,0)	MA	0.000
SARIMA (2,0,0)	AR 1	0.000	signifikan
	AR 2	0.005	signifikan
	SAR	0.000	signifikan

### 4) Diagnostic Checking

Pada tahap ini ada 2 uji yang pertama uji *white noise*, signifikan ketika nilai p-value > 5% yang dapat dilihat pada uji Ljung-Box pada Tabel 3.5 dan uji normalitas residual, terpenuhi jika P-value > 0.05 pada Gambar 3.5

Tabel 3. 4 Uji Ljung-box

Model	lag	P-value	Keterangan
SARIMA (0,1,1) (1,0,0)	12	0.328	White noise
	24	*	-
	36	*	-
SARIMA (2,0,0) (1,1,0)	12	0.341	White noise
	24	*	-
	36	*	-



Tabel 3. 5 Plot Normalitas

Berdasarkan tabel 3.5, bahwa dapat diketahui model parameter yang memenuhi residual normal adalah SARIMA (2,0,0) (1,1,0) dengan p-value sebesar 0,15>0.05, maka model tersebut dapat digunakan sebagai model terbaik dan tidak diperlukan perbandingan nilai *Mean Square Error* (MSE).

5) Evaluasi Hasil Peramalan

Hasil analisis peramalan produksi padi dengan data training didapatkan nilai *Mean Square Error* (MSE) sebesar 0.043918 dan sebesar 0.3005793 untuk data testing, jarak MSE keduanya jauh berbeda. Dikatakan baik jika nilai MSE dari *predict* data *testing* mendekati nilai MSE data *training* karena uji model menggunakan data training sebanyak 36.

2. Support Vector Machine (SVM)


a) Pre- Processing data

Pada proses ini dilakukan uji normalitas dari 48 data, karena data menunjukkan tidak normal maka harus dilakukan *transformasi*. Kemudian pembagian data yang meliputi data pelatihan (*training*) 70% dari dari 48 diperoleh periode tahun 2013-2015 dan untuk data testing diperoleh dari 12 periode di tahun 2016.

b) Pemodelan SVM


Sebagai berikut hasil plotting data hasil *transformasi*. Seperti yang terlihat pada Gambar 3.4 bahwa sumbu x menunjukkan periode waktu dan sumbu y menunjukkan hasil produksi padi setiap bulan.





Gambar 3. 4 Hasil Plot data R

Untuk membangun model svm, maka digunakan *package(e1071)*. Hasil nilai prediksi dari *data training* terlihat pada Gambar 3.5, nilai tersebut telah ditentukan secara *default* oleh sistem dan belum diatur tipe kernel serta nilai parameternya. Untuk mendapatkan hasil yang maksimal maka perlu ditingkatkan dengan melakukan *tuning* model atau pengoptimalan parameter dengan *Grid Search Optimization(GSO)*




Gambar 3. 5 Plot prediksi *training*

Cara untuk melakukannya adalah dengan *grid search* dengan dimana akan melatih banyak model, Pada penelitian ini menggunakan kernel *radial basis function* yang telah dijelaskan sebelumnya pada bab metodologi. Setelah itu sistem akan melatih model dengan  $\epsilon = 0,0.1,0.2, \dots,1$  dan  $\text{cost} = 2^{-5},2^{-4},2^{-3}, \dots, 2^{-15}$  serta  $\text{gamma} = 2^{-15},2^{-14},2^{-13}, \dots, 2^{-3}$  yang berarti akan melatih beberapa pasangan model dimana cukup memerlukan waktu yang lama untuk melihat hasilnya. *Ranges* parameter tersebut ditentukan berdasarkan yang digunakan dalam penelitian secara umum(StackExchange. (n.d.), 2017). Sistem perhitungan dalam *Grid-search* hasil implementasi dari *k-fold cross validation*. Hasil optimasi parameter sebagai berikut:

```
Parameter tuning of 'svm':
- sampling method: 10-fold cross validation
- best parameters:
  epsilon cost gamma
    0.4 32 8
- best performance: 0.2874773
```

Gambar 3. 6 Hasil optimasi parameter

Berdasarkan Gambar3.7 bahwa plot tersebut menunjukkan hasil prediksi dari optimasi parameter menggunakan *grid-search*



Gambar 3. 7 Hasil prediksi grid-search

Sebagai berikut nilai dari prediksi data training:

1	2	3	4	5	6	7	8	9
9.185551	9.964466	10.440553	10.354013	9.874668	9.523145	9.658434	10.034299	10.024405
10	11	12	13	14	15	16	17	18
9.357979	8.502294	8.214112	8.784843	9.791182	10.505749	10.497589	9.944116	9.460230
19	20	21	22	23	24	25	26	27
9.537278	10.030071	10.263965	9.784659	8.947908	8.595763	9.144530	10.142504	10.762737
28	29	30	31	32	33	34	35	36
10.614239	10.023913	9.615193	9.679164	9.935412	9.880000	9.354188	8.730668	8.524319

Kemudian, untuk memprediksi periode selanjutnya dengan menggunakan parameter dari hasil optimalisasi, Pada data uji hanya perlu memasukkan model SVM terbaik beserta parameternya dari hasil yang telah didapatkan yaitu dengan model  $(\epsilon, \cos, \gamma) = (0.4, 32, 8)$ . Hasil *predict* dari data *testing* sebagai berikut:

1	2	3	4	5	6	7	8	9	10
9.74365	9.74365	9.74365	9.74365	9.74365	9.74365	9.74365	9.74365	9.74365	9.74365
11	12								
9.74365	9.74365								

#### c) Evaluasi Hasil Peramalan

Hasil peramalan menunjukkan nilai *Mean Square Error* (MSE) pada data produksi padi tahun 2013-2014 dari hasil selesih antara nilai prediksi dengan data aktual menunjukkan nilai *Mean Square Error* (MSE) data *training* sebesar 0.14 sedangkan untuk data *testing* diperoleh 0.57.

#### 4. KESIMPULAN

Kesimpulan yang diperoleh dari hasil penelitian yang telah dilakukan yaitu sebagai berikut:

- 1) Model yang didapatkan dari metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) adalah SARIMA (2,0,0)(1,1,0) dengan nilai *Mean Square Error* (MSE) sebesar sebesar 0.043918 dari data *training* dan sebesar 0.3005793 dari hasil prediksi data *testing*.

- 2) Untuk model Support Vector Machine (SVM) diperoleh dari optimasi menggunakan *grid-search* didapatkan parameter model  $(\epsilon, \text{COS}, \gamma) = (0.4, 32, 8)$  dan hasil nilai *Mean Square Error* (MSE) data testing 0.57 dan data *training* yang merupakan hasil peramalan didapatkan MSE sebesar 0.14. maka hasil dari keduanya sangat dekat sehingga ramalan yang dihasilkan baik dan dapat diimplementasikan.

## REFERENSI

- BPS-statistics of Kendal Regency. (2017). *Kendal Dalam Angka 2017*. Kendal. <https://kendalkab.bps.go.id/Subjek/view/id/22>
- Fei, S., & Sun, Y. (2008). *Forecasting dissolved gases content in power transformer oil based on support vector machine with genetic algorithm* (Vol. 78). China. <https://www.deepdyve.com/lp/elsevier/forecasting-dissolved-gases-content-in-power-transformer-oil-based-on-bLpxkPux2R>
- Nello Cristianini. (2002). Choosing Multiple Parameters for Support. *Machine Learning*, 131–159.
- Nugroho, A. S., Witarto, A. B., & Handoko, D. (2003). Support Vector Machine. *Teori Dan Aplikasi Dalam Bioinformatika*. Retrieved from [KuliahUmumIlmuKomputer.com](http://KuliahUmumIlmuKomputer.com)
- Supriatna, A., Subartini, B., & Hertini, E. (2017). Prediksi Wisatawan Mancanegara Ke Jawa Barat Melalui Pintu Masuk Bandara Husein Sastranegara dan Pelabuhan Muarajati Menggunakan Metode SARIMA.
- Lipo Wang (Ed.), L. (2005). *Support Vector Machines Theory and Application*. (P. J. K. R. Institute), Ed.). Singapore: Springer, Poland.
- Darmawan, A. I. (2004). Pertanian Mandiri. In S. Y. Husodo. Jakarta: Swadaya.
- Dinas Pertanian, P. P. (2016). Kendal: DP3K.
- StackExchange. (n.d). (2017, June 04). *Which search range for determining SVM optimal C and gamma parameters.*
- Wei, W. (1990). *Time Series Analysis*. Canad: Addison Wesley Publishing Company.