

## *Planning Total Veneer Production PT. XYZ*

### **Perencanaan Jumlah Produksi (Veneer) PT. XYZ**

Krisna Risky Putra Irawan<sup>1</sup>, Tedjo Sukmono<sup>2</sup>  
{[krisna97.ki@gmail.com](mailto:krisna97.ki@gmail.com)<sup>1</sup>, [thedjoss@gmail.com](mailto:thedjoss@gmail.com)<sup>2</sup>}

<sup>1</sup>Program Studi Teknik Industri, Fakultas Sains dan teknologi,  
Universitas Muhammadiyah Sidoarjo

**Abstract.** *PT. XYZ is engaged in the manufacture and sale of wood veneers. Starting from the constant occurrence of over stock, now the company must make improvements to the production forecasting process so that over stock can be avoided. It can be seen that accurate production forecasting can create conditions for an effective and efficient production system. This study aims to obtain a more accurate forecast of material requirements using the Support Vector Regression (SVR) method, which is the result of the development of a Support Vector Machine (SVM) which has good performance in predicting time series data. Application of the Support Vector Regression (SVR) method with the RBF kernel in predicting the need for veneer production using the MATLAB application, it produces the smallest error rate with a MAPE of 5%, RMSE of 4364.63 and R<sup>2</sup> of 0.748274147. on 67 training data and 20 testing data.*

**Keywords :** *Forecasting Production, Support Vector Regression, Root Mean Square Error, Mean Absolute Percentage Error, Koefisien Determinasi.*

**Abstrak.** *PT. XYZ bergerak dalam bidang pembuatan dan penjualan Veneer kayu. Berawal dari selalu terjadinya over stock, kini perusahaan harus melakukan perbaikan pada proses peramalan produksi agar over stock bisa dihindarkan. Dapat diketahui bahwa peramalan produksi yang tepat dapat menciptakan kondisi sistem produksi yang efektif dan efisien. Penelitian ini bertujuan untuk mengakurasi hasil peramalan kebutuhan material yang lebih akurat dengan menggunakan metode Support Vector Regression (SVR) yang merupakan hasil pengembangan Support Vector Machine (SVM) yang mempunyai performa yang baik dalam prediksi data time series. Penerapan metode Support Vector Regression (SVR) dengan kernel RBF dalam meramalkan kebutuhan produksi veneer menggunakan aplikasi MATLAB ini menghasilkan tingkat error terkecil dengan MAPE sebesar 5%, RMSE sebesar 4364,63 dan R<sup>2</sup> sebesar 0,748274147. pada pengujian 67 data training dan 20 data testing.*

**Kata kunci :** *Peramalan Produksi, Support Vector Regression, Root Mean Square Error, Mean Absolute Percentage Error, Koefisien Determinasi.*

## **I. PENDAHULUAN**

PT. XYZ perusahaan ini bergerak dalam bidang pembuatan dan penjualan Veneer kayu. Veneer adalah lembaran tipis dari blok dengan ketebalan berkisar antara 0,25 mm sampai 3 mm dikupas dari log, blok, atau kayu persegian. Berawal dari selalu terjadinya over stock, dikarenakan selalu adanya perbedaan pada peramalan produksi dengan penjualan yang rata-rata selisihnya mencapai 10.269 m<sup>2</sup> dengan RMSE sebesar 15048 tiap minggunya kini perusahaan harus melakukan perbaikan di proses peramalan produksi agar over stock bisa dihindarkan kondisi seperti ini menuntut perusahaan agar dapat menyelesaikan setiap produksinya sesuai dengan kebutuhan dan kualitas yang direncanakan agar lebih efisien dan meminimalkan kemungkinan kerugian akibat over stock.

Karena pentingnya peramalan produksi maka penulis akan melakukan penelitian pada metode peramalan *Support Vector Regression* (SVR) dengan tujuan mengetahui kernel terbaik yang dapat digunakan untuk melakan peramalan produksi veneer PT. XYZ dengan menggunakan data penjualan veneer.

### **Veneer**

Veneer kayu adalah lembaran kayu dengan ketebalan 0.25 mm hingga 3 mm yang didapat melalui melalui beberapa proses mulai dari pemotongan hingga sampai ke proses pengupasan. Ada beberapa jenis kayu yang dapat diolah menjadi veneer seperti kayu jati, kayu sungkai, kayu mindi, kayu amara, kayu sengon, serta kayu oak dan masih banyak yang lainnya. Veneer kayu kerap menjadi pilihan sebagai material finishing baik untuk perabot ataupun material mentah seperti papan kayu lapis ataupun papan kayu blockboard untuk membantu permukaan material tersebut menjadi lebih rata. Selain sebagai material finishing, veneer kayu yang memiliki ketebalan yang diatan 1mm kerap menjadi bahan mentah pembuatan material lainnya seperti pembuatan kayu

lapis yang kemudian bisa diolah kembali menjadi perabot atau furnitur. Veneer kayu juga tak jarang digunakan sebagai pelapis lantai parket, atau langsung diaplikasikan sebagai pengganti HPL atau material finishing lainnya

### Peramalan

Peramalan merupakan tata cara untuk memperkirakan sesuatu nilai dimasa depan dengan memakai data masa lalu. Peramalan pula bisa dimaksud bagaikan seni serta ilmu untuk memperkirakan peristiwa pada masa yang hendak tiba, sebaliknya kegiatan peramalan ialah sesuatu peranan bisnis yang berupaya memperkirakan penjualan serta pemakaian sesuatu produk sehingga bahan-bahan itu bisa terbuat dalam jumlah yang pas[1].

Peramalan dapat diartikan sebagai upaya untuk meramalkan masa depan dengan menggunakan cara kualitatif atau [2]. Ini adalah bagian integral dari semua aktivitas manusia, tetapi dari sudut pandang bisnis, perhatian yang semakin meningkat diberikan pada sistem peramalan formal yang terus disempurnakan. Setiap bentuk pengambilan keputusan dan kegiatan perencanaan dalam bisnis tanpa pengecualian bagi bisnis angkutan udara mengadopsi peramalan. Ada dua teknik yang terlibat dalam peramalan: teknik kualitatif yang melibatkan penggunaan metode kausal seperti analisis korelasi dan regresi, dan analisis deret waktu seperti analisis tunggal[3].

### Data time series

Data time series adalah serangkaian pengamatan yang terurut berdasarkan waktu dengan jarak waktu yang sama. Jenis data tersebut sering ditemui dalam keseharian karena data-data ini dikumpulkan melalui waktu interval dalam harian, mingguan, bulanan atau bahkan tahunan. Dari data yang terkumpul dapat dilihat suatu pola didalamnya. Ada tiga pola yang dipakai dalam *time series* yaitu pola trend, siklis dan musiman (seasonal). Pola musiman (seasonal) merupakan pola yang mengalami pengulangan yang sama berkali-kali di interval tertentu[4].

Berdasarkan pembagian daerah (domain), ada dua daerah (domain) pada Data time series yaitu daerah waktu (time domain) dan daerah frekuensi (frekuensi domain). Daerah waktu berhubungan tentang signifikansi autokorelasi, kestasioneran data, penaksiran parameter model regresi deret waktu dan peramalan (forecasting). Sedangkan daerah frekuensi (frequency domain) berhubungan dengan frekuensi tersembunyi pada data musiman yang sulit diperoleh dalam daerah waktu. Tujuannya ialah untuk mengetahui kondisi tertentu atau hal-hal istimewa pada data. Salah satu cara yang bisa digunakan untuk analisis daerah frekuensi adalah analisis spektral **limam**.

Data deret waktu merupakan jenis data yang sering dikembangkan untuk kasus peramalan. Peramalan yang menggunakan data deret waktu dalam perkembangannya menunjukkan bahwa keakuratan peramalan dapat ditingkatkan dengan menggabungkan beberapa model dengan kombinasi daripada hanya menggunakan salah satu model terbaik[5].

### Support Vector Regression (SVR)

Support Vector Regression (SVR) merupakan suatu metode yang diperoleh dari pengembangan metode Support Vector Machine (SVM) [6], Support Vector Regression merupakan algoritma machine learning yang mampu mengenali pola Data time series dan juga mampu memberikan hasil sebuah prediksi yang baik. SVR diciptakan dengan tujuan untuk memecahkan masalah pemodelan dalam bentuk regresi dan time series. SVR adalah metode yang menggunakan konsep dari structural risk minimization, yaitu mengestimasi suatu fungsi dengan meminimalkan batas yang ada pada generalization error sehingga dapat mengatasi overfitting. Dengan SVR, kita dapat menemukan suatu fungsi  $f(x)$  yang mempunyai deviasi ( $\epsilon$ ) paling besar dari target aktual  $y_i$  untuk semua data training. Pada model regresi untuk mendefinisikan hubungan antara  $x_i$  dan  $f(x_i)$  sebagai berikut[7]:

$$f(x_i) = w\varphi(x_i) + b \quad (1)$$

Dimana  $\varphi(x_i)$  merujuk kepada suatu titik didalam feature space F (ruang koordinat yang dimuati oleh fungsi) hasil pemetaan  $x$  di dalam input space. Parameter  $w$  dan  $b$  adalah parameter bobot dan bias dari persamaan regresi. Nilai dari  $w$  dan  $b$  dapat di estimasi dengan cara meminimalkan fungsi resiko (risk function) yang didefinisikan dalam permasalahan optimasi berikut:

$$\min \left( \frac{1}{2} \|w\|^2 + C \frac{1}{n} \sum_{i=1}^n L_{\epsilon}(y_i, f(x_i)) \right) \quad (2)$$

dengan kendala:

$$y_i - w\varphi(x_i) - b \leq \epsilon \quad (3)$$

$$w\varphi(x_i) - y_i + b \leq \epsilon, i = 1, \dots, n \quad (4)$$

dengan

$$\sum_{i=1}^n L_{\epsilon}(y_i, f(x_i)) = \begin{cases} |y_i - f(x_i)| - \epsilon & \text{jika } |y_i - f(x_i)| \geq \epsilon \\ 0 & \text{untuk yang lain} \end{cases} \quad (5)$$

Faktor  $\|w\|^2$  yang disebut juga regularisasi (keteraturan). Meminimumkan  $\|w\|^2$  dapat menjadikan suatu fungsi memiliki jarak yang saling berdekatan, sehingga bisa mengontrol kapasitas fungsi. Faktor kedua dalam fungsi tujuan adalah kesalahan emperis (empirical error) yang dapat diukur dengan

$\varepsilon$  – insensitive loss function. Supaya bisa mendapatkan generalisasi yang baik untuk fungsi regresi  $f$  maka  $\|w\|^2$  harus diminimalkan dengan cara menyelesaikan permasalahan optimasi berikut:

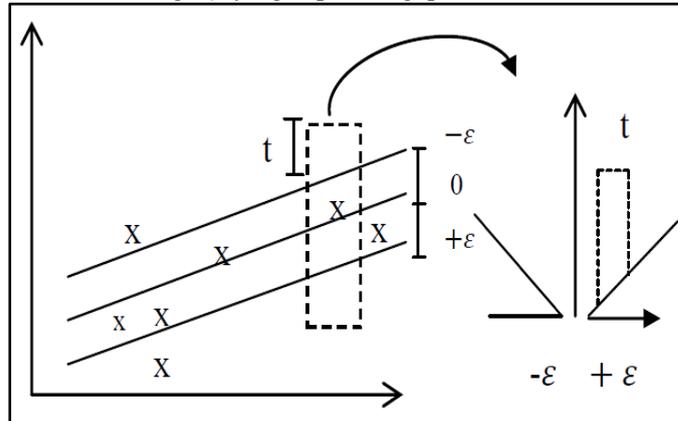
$$\min \frac{1}{2} \|w\|^2 \quad (6)$$

dengan kendala:

$$y_i - w\varphi(x_i) - b \leq \varepsilon \quad (7)$$

$$w\varphi(x_i) + b - y_i \leq \varepsilon \quad (8)$$

Kita asumsikan bahwa ada suatu fungsi  $f$  yang dapat mengaproksimasi semua titik  $(x_i, y_i)$  dengan presisi  $\varepsilon$ .



Gambar 1.  $\varepsilon$ -insensitive loss function

Dari gambar 1 dapat diartikan bahwa semua titik di luar area dikenai pinalti. Dalam kasus ini kita asumsikan bahwa semua titik yang berada dalam rentang  $f \pm \varepsilon$  (feasible). Dan titik yang berada di luar rentang  $f \pm \varepsilon$  adalah ketidak layakan (infeasibility), kita bisa menambahkan variable slack  $t$  untuk mengatasi masalah pembatasan yang tidak layak (infeasible constraints) dalam problem optimasi.

$$\min_{w,b,\xi^*} \left( \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \right) \quad (9)$$

dengan kendala

$$y_i \leq ((w \cdot x_i) + b) + \varepsilon + \xi_i, i = 1, \dots, n \quad (10)$$

$$y_i \geq ((w \cdot x_i) + b) - \varepsilon - \xi_i^*, i = 1, \dots, n \quad (11)$$

$$\xi_i \geq 0, \quad \xi_i^* \geq 0$$

Dengan kata lain, untuk menentukan nilai parameter  $w$  dan  $b$  menjadi masalah pemrograman kuadrat (quadratic programming), yaitu untuk meminimumkan suatu fungsi kuadrat dengan syarat suatu pertidaksamaan Linear.

Cara yang umum untuk digunakan dalam menyelesaikan pemrograman kuadrat tersebut, adalah mencari bentuk dual dengan menggunakan perkalian lagrange (lagrange multipliers). Dengan menggunakan pengali  $\alpha_i$  dan  $\alpha_i'$ , dimana  $\alpha_i$  dan  $\alpha_i'$  adalah variabel non-negatif, maka bentuk primal pemrograman kuadrat dapat diubah menjadi bentuk dual sebagai berikut [8]:

$$\max \left( \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \alpha_i') (\alpha_i - \alpha_i') K(x_i x_j) + \sum_{i=1}^l y_i \left( (\alpha_i - \alpha_i') - \varepsilon \sum_{i=1}^l (\alpha_i - \alpha_i') \xi_i^* \geq 0 \right) \right) \quad (12)$$

dengan kendala

$$\sum_{i=1}^l (\alpha_i - \alpha_i') = 0 \quad (13)$$

$$0 \leq \alpha_i \leq C, i = 1, \dots, l \quad (14)$$

Berikut ini adalah fungsi regresi dengan menggunakan lagrange multiplier dan kondisi optimalitas:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i') K(x_i, x) + b \quad (15)$$

Dimana  $K(x_i, x)$  didefinisikan melalui fungsi kernel dan  $w = (\alpha_i - \alpha_i')$ .

### Normalisasi dan Denormalisasi data

Normalisasi data adalah cara untuk mengubah data untuk mendapatkan nilai yang memiliki kekuatan sama besar. Normalisasi memiliki tujuan untuk mendapatkan data dengan ukuran yang lebih kecil yang dapat mewakili data yang asli tanpa kehilangan karakteristiknya sendiri[9]. SVR mampu bekerja dengan efektif jika data mempunyai rentang skala kecil. Maka dari itu metode yang dipilih untuk menormalisasi data adalah metode min-max dikarenakan metode normalisasi ini menskalakan ulang secara Linear data dari satu rentang nilai untuk rentang baru nilai-nilai, seperti [0,1] atau [-1,1]. Proses normalisasi dilakukan sebelum melakukan pelatihan menggunakan SVR dengan menggunakan rumus [5]:

$$\text{normalisasi} = \frac{x - \min_A}{\max_A - \min_A} \quad (16)$$

Denormalisasi merupakan proses mengembalikan data ke nilai awal yang sebelumnya sudah melewati proses normalisasi proses ini bertujuan untuk mendapatkan data asli. Denormalisasi dilakukan pada hasil akhir atau

output dari training peramalan. berikut adalah rumus denormalisasi:

$$\text{denormalisasi} = y(\max_A - \min_A) + \min_A \quad (17)$$

Dengan

- $x$  : data input ke-i
- $y$  : hasil peramalan awal
- $\min_A$  : nilai terkecil dari data awal
- $\max_A$  : nilai terbesar dari data awal

### Kernel

Metode kernel memberikan pendekatan alternatif dengan cara melakukan pemetaan data dari *input space* ke *feature space*  $F$  melalui suatu fungsi  $\phi$  sehingga  $\phi: x \rightarrow \phi(x)$ . Karena itu suatu titik  $x$  pada *input space* menjadi  $\phi(x)$  di *feature space*. Pemetaan input space ke *feature space*. Hal ini menyebabkan  $K(x, x') = \phi(x) \cdot \phi(x')$  dimana  $(x)$  merupakan operasi perkalian dalam. Selanjutnya kita bisa membuat suatu fungsi pemisah yang *linear* yang mewakili fungsi *nonlinear* di input space. Penggunaan fungsi kernel yang berbeda akan memberikan hasil model regresi yang berbeda pula. Fungsi kernel yang sering dipakai dalam literatur SVR sebagai berikut:

1. *Linear*

$$K(x, x') = x^T y \quad (18)$$

2. *Polynomial*

$$K(x, x') = (x^T x_i + 1)^p \quad (19)$$

3. Radial basis function (RBF)

$$K(x, x') = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (20)$$

Fungsi kernel manakah yang paling baik untuk digunakan dalam substitusi *dot product* di *feature space* sangat bergantung pada data. Biasanya dalam pemilihan fungsi kernel ini menggunakan metode *cross-validation*. Pemilihan fungsi kernel yang tepat merupakan hal yang sangat penting dikarenakan fungsi kernel ini akan menentukan *feature space* di mana fungsi *classifier* akan dicari. Sepanjang fungsi kernelnya *legitimate*, SVR akan beroperasi secara baik walaupun kita tidak tahu seperti apa *map* yang digunakan.

### Akurasi hasil peramalan

Tidak ada peramalan yang 100% tepat, peramalan akan memberikan peluang terjadinya kesalahan peramalan (error). Maka dari itu, peramalan yang baik adalah peramalan yang dapat meminimalkan error pada batas yang ditoleransi. Ukuran akurasi hasil peramalan yang merupakan ukuran kesalahan peramalan merupakan ukuran tentang tingkat perbedaan antara hasil peramalan dengan permintaan yang sebenarnya terjadi. Terdapat beberapa ukuran yang biasa digunakan.

Kinerja prediksi dievaluasi menggunakan root mean square error (RMSE), RMSE memberikan ilustrasi tentang baik atau buruknya akurasi sebuah prediksi yang dilakukan, RMSE merupakan ukuran dari sebuah kesalahan rata-rata menurut kuadrat kesalahan. RMSE dapat dirumuskan sebagai berikut [10]:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (A_t - F_t)^2}{n}} \quad (21)$$

MAPE merupakan persentasi kesalahan hasil peramalan terhadap permintaan aktual sepanjang periode tertentu yang hendak membersihkan data persentasi kesalahan sangat besar ataupun sangat rendah. Secara matematis, MAPE dirumuskan sebagai berikut [1]:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad (22)$$

1. *Koefisien Determinasi* ( $R^2$ )

*Koefisien determinasi* ( $R^2$ ) merupakan proporsi variasi total di sekitar nilai tengah  $y$  yang dapat dijelaskan oleh variasi regresi. Dijelaskan bahwa semakin tinggi nilai  $R^2$ , maka semakin besar variasi yang dapat dijelaskan.  $R^2$  dapat dirumuskan sebagai berikut:

$$R^2 = 1 - \frac{SS \text{ Error}}{SS \text{ Total}} = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2} \quad (23)$$

## II. METODE

Dataset yang digunakan dalam penelitian ini diambil dari database perusahaan. Dataset terdiri dari data penjualan tiap minggu selama 2 tahun sebanyak 88 data penjualan dari bulan Januari 2018 sampai bulan September 2019. Selanjutnya data dibagi menjadi 2 yaitu data training sebanyak 67 data aktual dan data testing sebanyak 21 data aktual.

Adapun proses dan perhitungan data yang akan dilakukan yaitu :

1. Normalisasi Data proses ini dilakukan dengan tujuan agar variasi tidak terlalu melebar.
2. Susun Data Masukkan data kedalam compiler Matlab, setelah membagi data menjadi data training dan testing kemudian data disusun seperti berikut:

Tabel 1. Bentuk penyusunan data

	$x_1$	$x_1$	$x_1$	$x_1$	<i>target</i>
Training	$data_1$	$data_2$	$data_3$	$data_4$	$data_5$
	$data_2$	$data_3$	$data_4$	$data_5$	$data_6$
	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
	$data_{63}$	$data_{64}$	$data_{65}$	$data_{66}$	$data_{67}$
Training	$data_{64}$	$data_{65}$	$data_{66}$	$data_{67}$	$data_{68}$
	$data_{65}$	$data_{66}$	$data_{67}$	$data_{68}$	$data_{69}$
	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
	$data_{84}$	$data_{85}$	$data_{86}$	$data_{87}$	$data_{88}$

3. Training data merupakan proses untuk mendapatkan nilai bobot ( $w$ ) dan bias ( $b$ ). Nilai dari  $w$  dan  $b$  akan dimasukkan ke model regresi
4. Testing data Untuk menguji apakah model yang terbentuk baik, maka dilakukan proses testing pada proses ini juga akan mendapatkan hasil peramalan dengan melakukan validasi nilai bobot ( $w$ ) dan bias ( $b$ ) yang didapat dengan menggunakan data *testing*
5. Denormalisasi Data dilakukan dengan tujuan agar besaran nilai kembali ke awal.
6. Hitung *ERROR* Pada tahap ini dilakukan proses perhitungan error menggunakan beberapa perhitungan ukuran error diantaranya adalah *Mean absolute percentage error* (MAPE), *Root Mean Square Error* (RMSE) dan *Koefisien determinasi* ( $R^2$ )

### III. HASIL DAN PEMBAHASAN

Pengujian yang dilakukan memiliki tujuan untuk mendapatkan stock yang optimal sehingga terhindar dari kelebihan stock maupun kekurangan stock dalam memenuhi permintaan konsumendan mampu mengetahui metode kernel terbaik untuk digunakan sebagai peramalan produksi veneer dengan tingkat error yang kecil. Pengujian dilakukan dengan menggunakan aplikasi matlab dan excel.

#### Normalisasi Data

Svr bekerja lebih efektif dengan data yang mempunyai rentang skala kecil, maka langkah awal yang harus dilakukan yaitu dengan menormalisasi data dengan rentang nilai antara 0 sampai 1. Berikut untuk perhitungan normalisasi.

$$\text{normalisasi } x_1 = \frac{x_1 - \min_A}{\max_A - \min_A}$$

$$\text{normalisasi } x_1 = \frac{101693 - 34507}{65028 - 34507}$$

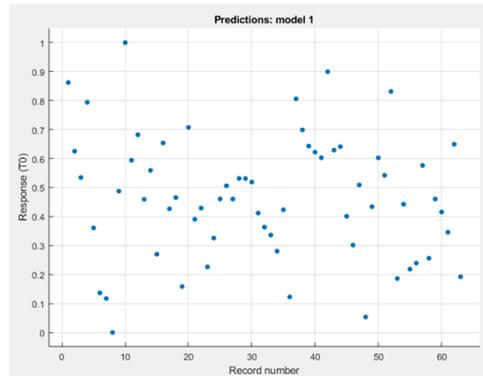
$$\text{normalisasi } x_1 = \frac{30521}{30521}$$

$$\text{normalisasi } x_1 = \frac{67186}{67186}$$

$$\text{normalisasi } x_1 = 0,454276188$$

#### Training data

pembentukan model dilakukan pada saat training data, poses training diawali dengan menginput data training dan melihat dimanakah posisi atau persebaran tiap-tiap data.



Gambar 2. Persebaran Tiap-Tiap Data

Dari gambar 2 diatas dapat dilihat bahwa persebaran data yang fluktuasi (yang menunjukkan naik-turunnya) penjualan *vener* pada tiap minggunya Selanjutnya adalah penentuan fungsi kernel, berikut adalah contoh salah satu fungsi kernel yaitu kernel RBF. Pada fungsi kernel RBF terdapat suatu parameter  $\sigma$  yang di inputkan secara auto (dipilihkan oleh sistem nilai terbaik).

$$K(x_1, x_1) = \exp\left(-\frac{(0,4543 - 0,6659)^2 - (0,6659 - 0,1840)^2}{2\sigma^2}\right)$$

Setelah didapat nilai  $K(x_1, x_1)$  selanjutnya nilai tersebut dibawa ke matriks dengan indeks  $i= 1$  dan  $j = 1$ . Nilai indeks  $i$  dan  $j$  terus berjalan hingga matriks kernel terisi nilai dengan ukuran matriks yang dibentuk sebesar  $67 \times 67$ .

$$\begin{bmatrix} K(x_1, x_1) & \dots & K(x_1, x_{67}) \\ \vdots & \ddots & \vdots \\ K(x_{67}, x_1) & \dots & K(x_{67}, x_{67}) \end{bmatrix}$$

### Testing data

Untuk melihat seberapa baik model yang terbentuk, selanjutnya kita lakukan validasi model dengan menggunakan data *testing*. Data yang digunakan untuk validasi model adalah data pada periode (68) hingga (88). Dari proses *testing* didapatkan nilai peramalan yang dapat dilihat

Tabel 1. Perbandingan data testing dan hasil peramalan

No	Data Testing	Hasil Peramalan		
		Rbf	Linear	Polynomial
1	0,435418	0,457106	0,46972	0,451954193
2	0,486456	0,427107	0,411359	0,407121365
3	0,443515	0,436145	0,424461	0,421101546
4	0,523041	0,505627	0,536522	0,562571847
5	0,500834	0,45088	0,463154	0,435302564
6	0,551856	0,449796	0,46383	0,439543109
7	0,463683	0,454275	0,471913	0,444375244
8	0,479237	0,435277	0,44594	0,419731172
9	0,477942	0,427482	0,433097	0,391893538
10	0,43	0,427281	0,4303	0,397080519
11	0,334177	0,438666	0,446972	0,412412167
12	0,418822	0,421841	0,418239	0,370321661
13	0,5302	0,428072	0,419771	0,387392168
14	0,507918	0,467667	0,478209	0,467244316
15	0,462239	0,486466	0,514479	0,498896206
16	0,497931	0,449409	0,465435	0,435800972
17	0,536555	0,427756	0,431926	0,395378026
18	0,467389	0,445021	0,456431	0,431926037
19	0,341038	0,446893	0,462173	0,434228165
20	0,341991	0,415799	0,414188	0,360137587
21	0,513693	0,4047	0,387088	0,324193322

### Denormalisasi

Sebelum melakukan perhitungan tingkat error nilai peramalan yang didapatkan kita denormalisasi terlebih dahulu agar nilai data kembali ke nilai awal sebelum dilalukannya perhitungan nilai error. Berikut untuk

perhitungan denormalisasi.

$$\begin{aligned} \text{denormalisasi} &= y(\max_A - \min_A) + \min_A \\ \text{denormalisasi} &= 0,457106 (101693 - 34507) + 34507 \\ \text{denormalisasi} &= 0,457106 (67186) + 34507 \\ \text{denormalisasi} &= 30711,15092 + 34507 \\ \text{denormalisasi} &= 65218,15 \end{aligned}$$

### Menghitung Error

Hasil dari peramalan SVR perlu dilakukan pengecekan keakuratan peramalan. Diagnostik model yang dapat digunakan adalah *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE) dan *Koefisien Determinasi* ( $R^2$ ). Diagnostik model dilakukan untuk mengetahui akurasi pada peramalan data *testing* berikut adalah hasil perhitungan nilai *error*:

Tabel 3. Bentuk penyusunan data

No	Kernel	MAPE	RMSE	$R^2$
1	Rbf	5%	4364,63	0,748227
2	Linear	1%	4549,32	0,641441
3	Polynomial	3%	5481,41	-0,05833

Dari gambar 3 diatas pada peramalan produksi *veneer* menggunakan metode SVR dengan kernel RBF mendapatkan nilai MAPE terhadap data aktual sebesar 5% yang memiliki arti *Highly accurate* atau akurasi yang tinggi, RMSE terhadap data aktual sebesar 4364,63 hal ini menandakan bahwa nilai *error* yang dihasilkan kecil (nilai prediksi mengandung kesalahan sekitar 4364,63m<sup>2</sup> *veneer* dan untuk  $R^2$  terhadap data aktual yaitu sebesar 0,748274147 dapat dijelaskan bahwa ketepatan hasil peramalan pada metode SVR dengan kernel RBF cukup baik dikarenakan nilai *R-square* yang mendekati satu, hal ini menunjukkan kernel RBF dapat menjelaskan variable kebutuhan produksi secara signifikan dengan melibatkan observasi masa lalu (histori) dari penjualan *veneer*.

Dari gambar 3 diatas pada peramalan produksi *veneer* menggunakan metode SVR dengan kernel *Linear* mendapatkan nilai MAPE terhadap data aktual sebesar 1% yang memiliki arti *Highly accurate* atau akurasi yang tinggi, RMSE terhadap data aktual sebesar 4549,32 hal ini menandakan bahwa nilai *error* yang dihasilkan kecil (nilai prediksi mengandung kesalahan sekitar 4549,32m<sup>2</sup> *veneer* dan untuk  $R^2$  terhadap data aktual yaitu sebesar 0,641441281 dapat dijelaskan bahwa ketepatan hasil peramalan pada metode SVR dengan kernel *Linear* cukup baik dikarenakan nilai *R-square* yang mendekati satu, hal ini menunjukkan kernel *Linear* dapat menjelaskan variable kebutuhan produksi secara signifikan dengan melibatkan observasi masa lalu (histori) dari penjualan *veneer*.

Dari gambar 3 diatas pada peramalan produksi *veneer* menggunakan metode SVR dengan kernel *Polynomial* mendapatkan nilai MAPE terhadap data aktual sebesar 3% yang memiliki arti *Highly accurate* atau akurasi yang tinggi, RMSE terhadap data aktual sebesar 5481,41 hal ini menandakan bahwa nilai *error* yang dihasilkan kecil (nilai prediksi mengandung kesalahan sekitar 5481,41m<sup>2</sup> *veneer* dan untuk  $R^2$  terhadap data aktual yaitu sebesar -0,058327459 dapat dijelaskan bahwa ketepatan hasil peramalan pada metode SVR dengan kernel *Polynomial* tidak cukup baik dikarenakan nilai *R-square* yang tidak mendekati satu, hal ini menunjukkan kernel *Polynomial* tidak dapat menjelaskan variable kebutuhan produksi secara signifikan dengan melibatkan observasi masa lalu (histori) dari penjualan *veneer*.

## IV. KESIMPULAN

Dari hasil penelitian dan analisa secara umum dapat disimpulkan bahwa jika dilihat dari hasil penelitian yang telah dilakukan yang berjudul perencanaan jumlah produksi (*veneer*) PT. XYZ dapat disimpulkan bahwa :

1. Dalam menggunakan metode SVR dengan kernel RBF untuk meramalkan kebutuhan produksi *veneer* pada PT. Adi Machinery Gemaperkasa dalam 21 minggu berturut-turut adalah 65218, 63203, 63810, 68478, 64800, 64727, 65028, 63752, 63228, 63214, 63979, 62849, 63267, 65928, 67191 dan 64701 dalam hal ini data hasil peramalan tersebut dapat digunakan sebagai bahan acuan untuk kebutuhan produksi *veneer* dalam proses produksi.

2. Penerapan metode *Support Vector Regression* (SVR) dengan kernel RBF dalam meramalkan kebutuhan produksi *veneer* menggunakan aplikasi MATLAB ini menghasilkan tingkat *error* terkecil dengan MAPE yang cukup kecil sebesar 5%, RMSE sebesar 4364,63 dan  $R^2$  sebesar 0,748274147. pada pengujian 67 data *training* dan 20 data *testing*.

## UCAPAN TERIMA KASIH

Dan tak lupa juga penulis menyampaikan ucapan terima kasih kepada seluruh pihak yang telah mendukung dan membantu sehingga penelitian ini bisa terselesaikan. Adapun pihak-pihak yang terlibat antara lain:

1. Bapak Tedjo Sukmono, ST, MT selaku dosen pembimbing.
2. Ayah dan ibu yang selalu mendukung dan selalu ikhlas mendoakan anak.
3. Kakak yang selalu mengingatkan dan mengemangati.
4. Ervin indarwati yang selalu mengingatkan dan menyemangati.
5. Rekan-rekan “yubi, oki, akbar” yang banyak memberi masukan dan solusi saat proses penelitian.

## REFERENSI

- [1] S. Wardah and I. Iskandar, “ANALISIS PERAMALAN PENJUALAN PRODUK KERIPIK PISANG KEMASAN BUNGKUS (Studi Kasus : Home Industry Arwana Food Tembilahan),” *J@ti Undip J. Tek. Ind.*, vol. 11, no. 3, p. 135, 2017.
- [2] D. R. Indah and E. Rahmadani, “Sistem Forecasting Perencanaan Produksi dengan Metode Single Eksponensial Smoothing pada Keripik Singkong Srikandi Di Kota Langsa,” *J. Penelit. Ekon. Akutansi*, vol. 2, no. 1, pp. 10–18, 2018.
- [3] A. Adetayo *et al.*, “Jurnal Penelitian Terapan Industri Metode Peramalan untuk Permintaan Penumpang Udara Domestik di Nigeria,” vol. 5, no. 2, pp. 146–155, 2018.
- [4] A. M. Al’afi, W. Widiart, D. Kurniasari, and M. Usman, “Peramalan Data Time Series Seasonal Menggunakan Metode Analisis Spektral,” *J. Siger Mat.*, vol. 1, no. 1, pp. 10–15, 2020.
- [5] E. M. Priliani, A. T. Putra, and M. A. Muslim, “Forecasting Inflation Rate Using Support Vector Regression (SVR) Based Weight Attribute Particle Swarm Optimization (WAPSO),” *Sci. J. Informatics*, vol. 5, no. 2, pp. 118–127, 2018.
- [6] B. H. Prakoso, “Pengaruh Preprocessing Data pada Metode SVR dalam Memprediksi Permintaan Obat,” *J. Sist. Teknol. Inf. Indones.*, vol. 2, no. 2, pp. 92–99, 2017.
- [7] Mustakim, A. Buono, and I. Hermadi, “Support Vector Regression Untuk Prediksi Produktivitas Kelapa Sawit Di Provinsi Riau,” *J. Sains, Teknol. dan Ind.*, vol. 12, no. 2, pp. 179–188, 2015.
- [8] L. Kunhui, L. Qiang, Z. Changle, and Y. Junfeng, “Time series prediction based on linear regression and SVR,” *Proc. - Third Int. Conf. Nat. Comput. ICNC 2007*, vol. 1, no. 2006, pp. 688–691, 2007.
- [9] N. D. Maulana, B. D. Setiawan, and C. Dewi, “Implementasi Metode Support Vector Regression ( SVR ) Dalam Peramalan Penjualan Roti ( Studi Kasus : Harum Bakery ),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 3, pp. 2986–2995, 2019.
- [10] J. Chen, H. Chen, Y. Huo, and W. Gao, “Application of SVR Models in Stock Index Forecast Based on Different Parameter Search Methods,” *Open J. Stat.*, vol. 07, no. 02, pp. 194–202, 2017.