

Model *Support Vector Regression (SVR)* Berdimensi Tinggi dengan Pendekatan Fungsi Kernel Berbeda untuk Peramalan Harga Saham TLKM: Sebuah Pemodelan Deret Waktu Selama Masa Pandemi Covid-19

Fahmi¹, Suherman², Suryati³, Mawarni, M.⁴, Hanafi⁵
(^{1,2,3,4,5}Jurusan Teknik Elektro, Politeknik Negeri Lhokseumawe,
¹*fahmi@pnl.ac.id (*penulis korespondensi)

²suherman@pnl.ac.id

³suryati@pnl.ac.id

⁴mawarni@pnl.ac.id

⁵hanafi@pnl.ac.id

Abstrak— Peramalan harga saham dengan menggunakan model yang akurat memiliki peran penting dalam menentukan pilihan investasi bagi para investor. Dengan akuratnya nilai ramalan yang diperoleh, maka resiko yang dihadapi bisa di minimalisir. Dalam studi ini, model peramalan yang digunakan adalah model *Support Vector Regression (SVR)* berdimensi tinggi dengan pendekatan kernel berbeda. Dari empat kernel yang digunakan (linier, polinomial, sigmoid, dan radial), model SVR dengan fungsi kernel linier dan sigmoid menghasilkan keakuratan yang paling bagus. Dengan demikian, model inilah yang dipakai dalam memprediksi harga saham TLKM untuk rentang waktu lima hari kedepan.

Kata Kunci: Peramalan, SVR, TLKM, Linier, Polinomial, Sigmoid, Radial

Abstract— Stock prices forecasting using accurate models play an important role in determining investment options for investors. By obtaining the accurate model, the risks can be minimized. In this study, we apply a high-dimensional Support Vector Regression (SVR) model with a different kernel approach. Of the four kernels used (linear, polynomial, sigmoid, and radial), the SVR model with the linear and sigmoid kernels function produce the best accuracy performance. Thus, these models are used to forecast the stock price of TLKM for the next five days.

Keywords: Forecasting; SVR; TLKM; Linear; Polynomial; Sigmoid; Radial

I. PENDAHULUAN

Peramalan merupakan salah satu hal yang sangat penting bagi pembuat keputusan dan pengambil kebijakan baik bersifat individu maupun organisasi. Dalam dunia investasi di pasar modal, model peramalan yang sesuai selalu menjadi rujukan bagi para investor sebelum memulai bisnisnya. Pasar modal (*capital market*) merupakan pasar yang memperjual belikan berbagai instrumen keuangan jangka panjang, termasuk diantaranya adalah saham. Saham suatu perusahaan di pasar modal merupakan salah satu media investasi yang paling populer, mengingat tawaran keuntungan yang diberikan sangat menarik [1]. Pada tahun 2017, IHSG berhasil mencatat rekor tertinggi sepanjang masa. Indeks ini mengalami kenaikan diatas 15%. IHSG, yang secara internasional dikenal dengan *Indonesia Composite Index (ICI)* atau *IDX Composite*, merupakan indeks yang mengukur performa semua saham yang tercatat pada papan utama dan papan pengembangan Bursa Efek Indonesia (BIE).

Ada begitu banyak perusahaan-perusahaan yang mencatatkan sahamnya di BEI, yang dalam perdangan saham dikenal dengan *emiten*. Salah satu perusahaan yang melakukan penawaran kepada investor-investor di bursa saham di Indonesia tersebut adalah PT. Telekomunikasi Indonesia (Persero) Tbk dengan kode TLKM. Perusahaan ini merupakan badan usaha milik negara yang bergerak di bidang jasa telekomunikasi dan jaringnagn di Indonesia [2]. Sebagai salah satu anggota dari indeks IHSG, saham TLKM telah menarik perhatian bagi investor di era digitalisasi ini.

Pandemi Covid 19 yang merebak pada awal tahun 2020 telah memberikan dampak yang cukup besar terhadap perekonomian dunia termasuk Indonesia. Diantara dampak

yang berimbas dari pandemik ini adalah bursa saham. IHSG sendiri yang terdiri dari gabungan saham-saham unggulan dari berbagai sektor juga mengalami keterpurukan di pertengahan tahun 2020. Meskipun dampak dari pandemi Covid-19 yang dihadapi saham TLKM tidak separah saham-saham di IHSG, akan tetapi tingkat ketahanan (*level resistance*) atau dukungan (*support*) perlu dilewati oleh TLKM untuk melihat arah pergerakan kedepan khususnya diakhir masa pandemik. Investasi saham pada pasar modal pada umumnya bersifat sangat fluktuatif, sehingga seringkali investor dihadapkan pada resiko yang tinggi. Untuk meminimalisir resiko yang mungkin terjadi, maka perlu ukuran untuk menafsirkan kondisi bisnis di waktu yang akan datang terlebih lagi dengan adanya dampak Covid-19 ini. Oleh karena itu model peramalan yang sesuai dan akurat sangat mendasar dalam menentukan perolehan keuntungan tinggi dengan resiko rendah dalam berinvestasi di bursa saham.

Ada berbagai model yang telah dikembangkan dalam metode peramalan, khususnya peramalan harga saham, baik model linier maupun model tak linier. Dalam studi ini, kami menggunakan model *support vector regression (SVR)* yang juga merupakan kelas tak linier di dunia pemodelan. Dalam beberapa dekade terakhir, SVR memiliki kelebihan dibandingkan model regresi lainnya. Model ini dikenal dengan pemetaan data *training* dalam ruang berdimensi tinggi melalui fungsi kernel. Model SVR telah banyak diterapkan dalam berbagai bidang disiplin ilmu, secara khusus dalam bidang peramalan saham diantaranya adalah peramalan harga saham dalam rentang waktu harian dan menit [3]; Analisa harga saham dengan model SVR [4]; Penerapan model SVR dalam memprediksi harga saham dengan metode genetika [5]; dan

Penerapan SVM-KNN dengan menggunakan SVR dalam menganalisa saham di bursa saham Indonesia [6].

Paper ini di bagi dalam beberapa bagian. Bagian berikutnya menjelaskan tentang teori dasar dari model yang diajukan. Bagian 3 menjelaskan metode penelitian. Bagian 4 membahas hasil penelitian. Dibagian 5 menyimpulkan hasil studi dan saran untuk penelitian lanjutan.

II. DASAR TEORI

2.1 Konsep Dasar Support Vector Regression (SVR)

Support Vector Regression (SVR) merupakan sebuah algoritma yang memberikan toleransi pada error ε terhadap batas yang telah ditentukan oleh *hyperplane*. SVR ini pertama kali diperkenalkan oleh Vapnik pada tahun 1995 [7]. Metode SVR dalam studi ini bertujuan mendapatkan fungsi $f(x)$ dengan sebaran ε pada bidang *hyperplane* sedater mungkin. Metode ini sejalan dengan algoritma yang dikembangkan oleh Somala [8]. Dari sampel data training $\{(x_i, y_i), i = 1, 2, \dots, \ell\} \subset \mathcal{X} \times \mathbb{R}$, dimana \mathcal{X} dinotasikan dengan ruang sampel dari *input vector*. $x_i \in \mathbb{R}^d$ dikenal sebagai *input vector* dengan dimensi n dan $y_i \in \mathbb{R}$ dinotasikan sebagai *output vector* yang saling berhubungan. Sehingga data training x_i dapat dihubungkan dengan *hyperplane* yang optimal berdimensi tinggi baik secara linier maupun tak linier antara *vector input* dan *vector output*. Secara matematis bentuk fungsi linier f dapat ditulis

$$f(x) = \langle \omega, x \rangle + b, \text{ dengan } \omega \in \mathcal{X}, b \in \mathbb{R} \quad (1)$$

dimana $\langle \omega, x \rangle$ dinotasikan dengan hasil perkalian titik dalam \mathcal{X} . Untuk memperoleh ω yang kecil, salah satu cara yang bisa digunakan adalah dengan meminimalkan norma ω , yaitu $\langle \omega, \omega \rangle$. Bentuk ini dapat ditulis dalam kasus optimasi konveks (*convex optimization*) sebagai berikut

$$\begin{aligned} \text{Min} \quad & \frac{1}{2} \|\omega\|^2 \\ \text{Subject to} \quad & \begin{cases} y_i - \langle \omega, x_i \rangle - b \geq \varepsilon \\ \langle \omega, x_i \rangle + b - y_i \leq \varepsilon \end{cases} \end{aligned} \quad (2)$$

Dari persamaan (2), bila pendekatan semua pasangan (x_i, y_i) memiliki ε yang sangat presisi, dimana $y_i - \langle \omega, x_i \rangle$ harus berada dalam ruang $\pm \varepsilon$. Apabila $y_i - \langle \omega, x_i \rangle$ keluar dari kisaran $\pm \varepsilon$, maka Vapnik memberikan solusi dengan memperkenalkan variabel *slack* (*slack variables* ξ_i, ξ_i^*) untuk mengatasi batasan-batasan dari masalah optimasi. Formula optimasi dengan melibatkan variabel *slack* tersebut dapat ditulis sebagai berikut


$$\text{Min} \quad \frac{1}{2} \|\omega\|^2 + C \frac{1}{N} \sum_{i=1}^{\ell} (\xi_i, \xi_i^*) \quad (3)$$

$$\text{Subject to} \quad \begin{cases} y_i - \langle \omega, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle \omega, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

Konstanta C menentukan seberapa besar toleransi error ε antara data training dengan bidang *hyperplane*. Permasalahan seperti ini dapat diatasi dengan fungsi ε -insensitive loss function sebagaimana dijelaskan persamaan berikut

$$|\xi|_{\varepsilon} := \begin{cases} 0, & \text{jika } |\xi| \leq \varepsilon \\ |\xi| - \varepsilon, & \text{lainnya} \end{cases} \quad (4)$$

Gambar 1 menjelaskan bahwa garis $-\varepsilon$ dan $+\varepsilon$ merupakan garis yang dilalui titik-titik data atau dengan kata lain disebut juga *support vector*. Garis tengah yang memisahkan antara $-\varepsilon$ dan $+\varepsilon$ disebut *hyperplane*. Titik-titik yang berada diluar daerah berarsir disebut dengan *variable slack*.



Gambar 1: Soft Margin Hyperplane SVR

Dari kebanyakan kasus masalah optimasi, penyelesaiannya akan lebih mudah bila dilakukan dengan pendekatan formulasi dual (*dual formulation*). Formulasi ini membuka ruang untuk perluasan dari fungsi linier ke fungsi tak linier.

2.2 Formulasi Dual (Dual Formulation) dan Program Kuadratik

Dalam masalah optimasi konveks, nilai optimal fungsi tujuan dari formulasi primal dan formulasi dual adalah sama. Program kuadratik merupakan permasalahan dalam mengoptimasi fungsi tujuan kuadratik dan juga merupakan salah satu bentuk yang paling sederhana dalam pemograman tak linier. Di bidang *machine learning*, *Lagrange multiplier* dan formulasi dual sangat terkenal terutama dalam masalah optimasi [9]. Fungsi *Lagrange* dapat menyelesaikan batasan-batasan dalam masalah optimasi sebagaimana dijelaskan dalam persamaan berikut

$$L := \frac{1}{2} \|\omega\|^2 + C \frac{1}{N} \sum_{i=1}^{\ell} (\xi_i, \xi_i^*) \quad (5)$$

$$\begin{aligned}
 & - \sum_{i=1}^{\ell} (\eta_i \xi_i + \eta_i^* \xi_i^*) \\
 & - \sum_{i=1}^{\ell} \alpha_i (\varepsilon + \xi_i - y_i + \langle w, x_i \rangle + b) \\
 & - \sum_{i=1}^{\ell} \alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle w, x_i \rangle - b)
 \end{aligned}$$

$$\begin{aligned}
 \alpha_i (\varepsilon + \xi_i - y_i + \langle w, x_i \rangle + b) &= 0 \\
 \alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle w, x_i \rangle - b) &= 0
 \end{aligned} \tag{31}$$

dan

$$\begin{aligned}
 (C - \alpha_i) \xi_i &= 0 \\
 (C - \alpha_i^*) \xi_i^* &= 0
 \end{aligned} \tag{42}$$

disini L adalah Lagrangian dan $\eta_i, \eta_i^*, \alpha_i, \alpha_i^*$ adalah pengali Lagrange. Untuk mendapatkan solusi yang optimal, maka L diturunkan secara parsial terhadap variabel-variabel primal $(\omega, b, \xi_i, \xi_i^*)$. Sehingga diperoleh:

$$\partial_b L = \sum_{i=1}^{\ell} (\alpha_i^* - \alpha_i) = 0 \tag{6}$$

$$\partial_{\omega} L = \omega - \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) x_i = 0 \tag{7}$$

$$\partial_{\xi_i^*} L = C - \alpha_i^* - \eta_i^* = 0 \tag{8}$$

Dengan mensubstitusikan persamaan (6), (7), dan (8) ke (5), maka bentuk lengkap dari masalah optimasi dual diperoleh sebagai berikut

$$\text{Max} \left\{ \begin{aligned} & -\frac{1}{2} \sum_{i,j=1}^{\ell} (\alpha_i^* - \alpha_i)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle \\ & -\varepsilon \sum_{i=1}^{\ell} (\alpha_i + \alpha_i^*) + \sum_{i=1}^{\ell} y_i (\alpha_i - \alpha_i^*) \end{aligned} \right. \tag{9}$$

Subject to $\sum_{i,j=1}^{\ell} (\alpha_i - \alpha_i^*) = 0$ dan $\alpha_i, \alpha_i^* \in [0, C]$

Dari persamaan (9), variabel dual η_i, η_i^* dapat dieliminasi dengan menggunakan persamaan (8), yang mana dapat diformulasikan sebagai $\eta_i^* = C - \alpha_i^*$. Dengan demikian, persamaan (8) dapat ditulis kembali seperti berikut

$$\begin{aligned}
 \omega &= \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) x_i, \text{ sehingga} \\
 f(x) &= \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b
 \end{aligned} \tag{20}$$

Persamaan ini dinamakan *Support Vector expansion*.

2.3 Karush–Kuhn–Tucker (KKT)

Untuk mendapatkan solusi dari pemrograman tak linier, maka kondisi KKT digunakan [10], [11]. Kondisi ini menyebutkan bahwa titik hasil dari perkalian antara variabel dual dengan batasan-batasan (*constrains*) harus dihilangkan.

Dari persamaan diatas hanya sampel (x_i, y_i) dengan $\alpha_i^* = C$ berada diluar error toleransi. Sedangkan $\alpha_i \alpha_i^* = 0$, sehingga diperoleh

$$\varepsilon - y_i + \langle w, x_i \rangle + b \geq 0 \text{ dan } \xi_i = 0 \text{ jika } \alpha_i < C \tag{53}$$

$$\varepsilon - y_i + \langle w, x_i \rangle + b \leq 0 \text{ jika } \alpha_i > 0 \tag{64}$$

Secara analogi, dapat ditulis

$$\begin{aligned}
 \max \{ & -\varepsilon + y_i - \langle w, x_i \rangle | \alpha_i < C \text{ atau } \alpha_i^* > 0 \} \\
 & \leq b \leq \\
 \min \{ & -\varepsilon + y_i - \langle w, x_i \rangle | \alpha_i > 0 \text{ atau } \alpha_i^* < C \}
 \end{aligned} \tag{75}$$

Dari persamaan (11) hanya untuk $|f(x_i) - y_i| \geq \varepsilon$ *Lagrange multiplier* tidak nol, atau dengan kata lain semua sampel dalam $\varepsilon -$ toleransi, dimana α_i, α_i^* dapat diselesaikan. Sedangkan untuk $|f(x_i) - y_i| < \varepsilon$, α_i, α_i^* haruslah nol, sehingga kondisi KKT dapat terpenuhi. Kondisi dimana $0 < \alpha_i < C$ dengan $\alpha_i^* = 0$ dan $0 < \alpha_i^* < C$ dengan $\alpha_i = 0$, dinamakan *support vector*.

2.4 Fungsi Kernel

Salah satu komponen paling penting dalam SVR adalah fungsi kernel. Fungsi ini mengubah masalah tak linier menjadi linier. Algoritma ini bergantung pada perkalian titik diantara x_i . Sehingga fungsi kernel $K(x, x') := \langle \Phi(x), \Phi(x') \rangle$ cukup untuk menjelaskan masalah optimasi *support vector*.

$$\begin{aligned}
 \text{Max} \left\{ \begin{aligned} & -\frac{1}{2} \sum_{i,j=1}^{\ell} (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j) \\ & -\varepsilon \sum_{i=1}^{\ell} (\alpha_i + \alpha_i^*) + \sum_{i=1}^{\ell} y_i (\alpha_i - \alpha_i^*) \end{aligned} \right. \tag{86} \\
 \text{Subject to} & \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) = 0 \text{ dan } \alpha_i, \alpha_i^* \in [0, C]
 \end{aligned}$$

Dengan demikian ekspansi fungsi dari persamaan (10) dapat ditulis sebagai berikut

$$\begin{aligned}
 \omega &= \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) \Phi(x_i) \text{ dan} \\
 f(x) &= \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) K(x_i, x) + b
 \end{aligned} \tag{97}$$

Ada beberapa fungsi kernel yang sering digunakan khususnya dalam *support vector*, diantaranya adalah fungsi

kernel Linier, fungsi kernel Polinomial, fungsi kernel Gaussian, dan fungsi kernel Sigmoid [12], [13]. Berikut adalah formula fungsi-fungsi kernel tersebut:

- Fungsi kernel Linier

Fungsi kernel ini merupakan fungsi kernel yang paling sederhana, yang ditandai dengan perkalian titik dari $x_i \cdot x$

$$K(x_i, x) = x_i \cdot x \quad (108)$$

- Fungsi kernel Polinomial

$$K(x_i, x) = (\alpha \langle x_i \cdot x \rangle + 1)^d \quad (19)$$

dimana α adalah kemiringan dan d adalah derajat polinomial

- Fungsi kernel Sigmoid

$$K(x_i, x) = \tanh(\gamma \langle x_i \cdot x \rangle + \theta) \quad (20)$$

dimana γ adalah kemiringan dan θ adalah konstanta intersep.

- Fungsi kernel Gaussian

$$K(x_i, x) = \exp\left(\frac{-\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (21)$$


dimana x_i variabel input dalam dimensi ke i^{th} dan x_j adalah sampel training dalam neuron j^{th} dari pola layer dengan lebar kernel σ .

3 METODOLOGI PENELITIAN

Dalam penelitian kuantitatif ini, data TLKM diperoleh dari <https://finance.yahoo.com>. Untuk kepentingan analisis, data ini diolah dengan menggunakan *software R-Studio*.

3.1 Data

Data yang digunakan dalam studi ini adalah data harian harga saham PT. Telekomunikasi Indonesia dengan kode indeks TLKM yang dimulai dari bulan Januari 2020 sampai dengan bulan Oktober 2020. Pengambilan data ini erat kaitannya dengan masa pandemi Covid-19 yang dimulai pada awal tahun 2020. Dari beberapa variabel harga saham (*open*, *high*, *low*, *close*), harga *close* adalah variabel yang digunakan dalam studi ini. Harga *close* ini merupakan harga terpenting dalam analisis teknikal. Harga ini mencerminkan semua informasi yang ada pada semua pelaku pasar pada saat perdagangan saham berakhir. Data ini terdiri dari 206 pengamatan yang mana secara visual dapat di lihat pada Gambar 2. Dari Gambar ini terlihat bahwa secara umum pergerakan harga TLKM cenderung menurun sejak awal Januari 2020. Penurunan yang signifikan terlihat pada akhir Februari dan awal Maret 2020. Kasus ini disebabkan karena periode tersebut diketahui terdeteksinya Covid-19 di Indonesia sehingga banyak investor asing yang menjual sahamnya sehingga berimbas pada jatuhnya harga saham TLKM.



Gambar 2. Nilai aktual harga saham TLKM

3.2 Metode

Metode SVR dalam penelitian ini diaplikasikan pada data saham TKLM. Data ini dibagi menjadi dua bagian, bagian pertama sebagai data *training* sedangkan bagian kedua sebagai data *testing*. Algoritma dari model SVR yang diajukan ini adalah sebagai berikut

Langkah 1: Tentukan input dan output dari data saham TLKM untuk peramalan dengan SVR,

Langkah 2: Bangun model peramalan dengan SVR:

- Tentukan dan normalisasi data training $T = \{(x_i, y_i), i = 1, 2, \dots, \ell\}$ seperti pada langkah 1,
- Pilih parameter SVR, misalnya C , ε , fungsi kernel $K(x_i, x)$,
- Tentukan masalah optimasi dan selesaikan dengan *Lagrange multiplier*,
- Tentukan fungsi regresi SVR $f(x) = \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) K(x_i, x) + b$,

Langkah 3: Pilih model SVR dengan melihat RMSE dan MAPE, jika keakuratan prediksi sesuai, maka model untuk peramalan TLKM sudah didapat. Akan tetapi jika sebaliknya, maka ubah dan sesuaikan parameter-parameter dan fungsi kernel.

Langkah 4: Ulangi langkah 1-3 untuk semua fungsi kernel

Untuk mengevaluasi kinerja keakuratan model, dua formula *error* digunakan, yaitu *Root Mean Square Error (RMSE)* dan *Mean Absolute Percentage Error (MAPE)*. Dua formula eror ini sangat sering dijumpai dalam banyak literatur, misalnya [14]. Bentuk matematis dari formula-formula ini adalah sebagai berikut:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_t - y_t)^2} \quad (22)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_t - y_t}{y_t} \right| \times 100\% \quad (23)$$

Dimana N adalah panjang rentang waktu peramalan, \hat{y}_i adalah nilai ramalan untuk waktu t , dan y_t adalah data aktual pada waktu .

4 HASIL DAN PEMBAHASAN

Dalam penelitian ini 201 pengamatan data saham TLKM (*training data*) di modelkan dengan *support vector regression* (SVR). Empat fungsi kernel (linier, polinomial, sigmoid, dan Radial) dicoba pada data tersebut untuk melihat kinerja dan perbandingan (*benchmarking*) dari model yang dikembangkan. Banyaknya data yang diprediksi (*forecast horizon*) dalam studi ini adalah hanya lima data (lima hari kerja dalam seminggu). Hal ini mengingat sensitifitas pandemi Covid-19 di Indonesia yang terus meningkat dan kehati-hatian dalam pengambilan keputusan dan kebijakan berdasarkan data hasil ramalan.

TABEL I
KINERJA KEAKURATAN MODEL SVR DENGAN FUNGSI KERNEL BERBEDA

Fungsi Kernel	RMSE	MAPE
<i>Linier</i>	81.84	2.37
<i>Polinomial</i>	418.15	15.33
<i>Sigmoid</i>	82.67	2.13
<i>Radial</i>	94.67	3.54


Tabel 1 menunjukkan kinerja keakuratan model SVR yang dikembangkan berdasarkan RMSE dan MAPE dengan pendekatan empat fungsi kernel. Dari empat fungsi kernel tersebut, model SVR yang menghasilkan RMSE dan MAPE terkecil adalah model dengan fungsi kernel linier. Sedangkan diurutan kedua adalah model SVR dengan fungsi kernel sigmoid. Fungsi kernel Linier unggul di RMSE dan fungsi kernel Sigmoid unggul di MAPE. Dua hasil ini mengalahkan RMSE dan MAPE dari model SVR dengan kernel Radial yang umumnya dipakai dalam pemodelan berdimensi tinggi seperti ini. Sedangkan hasil RMSE dan MAPE terburuk dari model SVR ini adalah model SVR dengan fungsi kernel Polinomial. Model SVR dengan fungsi kernel linier mampu meningkatkan keakuratan model sebesar 80% untuk RMSE dan 85% untuk MAPE jika dibandingkan dengan model SVR dengan fungsi kernel polinomial. Jika dibandingkan dengan model dengan fungsi kernel radial, model SVR dengan fungsi kernel linier mampu memperbaiki 14% RMSE dan 33% MAPE. Begitu juga dengan model SVR dengan fungsi kernel sigmoid yang mana mampu memperbaiki keakuratan ramalan tidak jauh beda dengan model SVR dengan fungsi kernel linier.

Hasil ini menunjukkan bahwa, partisipasi fungsi kernel linier dan sigmoid dalam model SVR ini mampu memperbaiki kemampuan *learning* dari SVR system dan menurunkan tingkat *error*. Sehingga model yang dipilih untuk meramalkan harga saham TLKM untuk jangka waktu lima hari kedepan adalah model SVR dengan fungsi kernel linier. Tabel 2 Menampilkan nilai-nilai hasil ramalan dari model SVR dengan empat fungsi kernel berbeda

TABEL 2
HASIL PERAMALAN LIMA HARI MODEL SVR DENGAN EMPAT FUNGSI KERNEL

Hari	SVR Kernel Linier	SVR Kernel Polinomial	SVR Kernel Sigmoid	SVR Kernel Radial
1	2632.72	2274.70	2623.07	2677.46
2	2626.72	2246.68	2616.95	2678.00
3	2620.72	2218.11	2610.84	2678.91
4	2614.72	2188.97	2604.74	2680.20
5	2608.72	2159.28	2598.66	2681.85

Perbandingan antara nilai aktual dan hasil ramalan dengan empat fungsi kernel pada model SVR ini secara visual dapat dilihat pada Gambar 3



Gambar 3. Nilai Aktual vs Nilai Ramalan model SVR dengan empat fungsi Kernel

Secara visual dari Gambar 3 masih mudah terlihat bahwa nilai ramalan model SVR dengan fungsi kernel linier dan sigmoid paling mendekati nilai aktual dibandingkan dengan model dengan fungsi kernel lainnya. Maka model SVR dengan fungsi kernel linier dan sigmoid dapat digunakan untuk meramal harga saham untuk rentang waktu lima hari kedepan (9 – 13, Oktober 2020).

5 KESIMPULAN

Keakuratan nilai ramalan merupakan masalah yang penting dalam perdagangan saham. Apabila error yang dihasilkan dari sebuah model untuk meramal harga saham di sebuah bursa saham terlalu besar, maka resiko tinggi yang

dihadapi oleh investor juga besar. Oleh karena itu sebuah keakuratan untuk meramal harga saham PT Telekomunikasi Indonesia dengan kode TLKM perlu melibatkan beberapa fungsi kernel sebagai pembandingan (benchmarking) dalam memilih model yang tepat. Dari hasil kajian ini, model SVR dengan fungsi kernel linier dan sigmoid telah menunjukkan performa yang signifikan dibandingkan tiga kernel lainnya, yaitu polynomial dan radial. Sehingga model SVR dengan fungsi kernel linier dan sigmoid dipilih untuk meramal harga saham TLKM. Sehubungan dengan kemampuan model SVR dalam memprediksi nilai data baik data dengan pola linier maupun tak linier, maka untuk penelitian lanjutan, perlu dicoba beberapa fungsi kernel lainnya selain empat fungsi kernel yang digunakan dalam studi ini, misalnya, *Bessel function kernel*, *Laplace Radial Basis Function (RBF) kernel*, *ANOVA radial basis kernel*, dan *linear splines kernel in one dimension*.

- [13] Kari, T., Gao, W., Tuluhong, A., Yaermaimaiti, Y., dan Zhang, Z., (2018), *Mixed Kernel Function Support Vector Regression with Genetic Algorithm for Forecasting Dissolved Gas Content in Power Transformers*, *Energies*, V.11, P. 2437
- [14] Yihua, Z., Lei, Z., Zhibin, L., Yao, X., dan Rong, L., (2010). *Using a support vector machine method to predict the development indices of very high water cut oilfields*, *Petroleum Science*, V.7, P. 379-384

REFERENSI

- [1] IDX, 2020, Saham. (Online) Tersedia di: <<https://www.idx.co.id/produk/saham/>> (diakses pada Oktober 2020)
- [2] Telkom, 2020. Tentang Telkomgroup. (Online) Tersedia di: <https://www.telkom.co.id/sites/about-telkom/id_ID/page/profil-dan-riwayat-singkat> (diakses pada Oktober 2020)
- [3] Henrique, B.M., Sobreiro, V.A., dan Kimura, H., 2018. Stock Price Prediction Using Support Vector Regression on Daily and Up to the Minute Prices, *The Journal of Finance and Data Science*, doi:10.1016/j.jfds.2018.04.003.
- [4] Kaur, S. dan Majithia, M.S., (2017), Stock Market Forecasting using Time Series Analytics with SVR, *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, Vol. 6, Issue 9, ISSN: 2278 – 1323
- [5] Putra, N.A., Setiawan, B.D. dan Adikara, P.P, (2018), Peramalan Harga Saham Menggunakan *Support Vector Regression* Dengan Algoritme Genetika, *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 2, No. 1, hlm. 209-216
- [6] Puspitasari, D.A., dan Rustam, Z., (2018). Application of SVM-KNN using SVR as feature selection on stock analysis for Indonesia stock exchange, *Proceedings of the 3rd International Symposium on Current Progress in Mathematics and Sciences (ISCPMS)*, AIP Conf. Proc. 2023, 020207-1–020207-7, Published by AIP Publishing.
- [7] Vapnik, V. and Cortes, C., (1995). *Support Vector Networks*, *Machine Learning*, V.20, P. 273–297.
- [8] Smola, A.J., dan Bernhard Scholkopf, B., (2004), A Tutorial on Support Vector Regression, *Statistics and Computing*, V.14, P. 199-222.
- [9] Wen, t. dan Edelman, a., (2000), support vector machine lagrange multipliers and simplex volume decompositions.
- [10] Karush, W., (1939), Minima of functions of several variables with inequalities as side constraints. *Master's thesis*, Dept. of Mathematics, Univ. of Chicago,
- [11] Kuhn, H.W., and Tucker, A.W., 1951. Nonlinear Programming. *Proc. Second Berkeley Symp. on Math. Statist. and Prob.*, Univ. of Calif. Press, P. 481-492
- [12] Karatzoglou, A. dan Meyer, D., (2006). *Support Vector Machines in R*, *Journal of Statistical Software*, V.15, Issue. 9.