

**SKRIPSI**

**ANALISIS *SUPPORT VECTOR REGRESSION* DENGAN  
*ALGORITMA GRID SEARCH TIME SERIES CROSS  
VALIDATION* UNTUK MERAMALKAN SAHAM  
PERUSAHAAN PERTAMBANGAN DI INDONESIA**



**AULYA ATIKA MAHGFIRAH  
E0220308**

**PROGRAM STUDI STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS SULAWESI BARAT  
TAHUN 2024**

## HALAMAN PENGESAHAN

Skripsi ini diajukan oleh:

Nama : Aulya Atika Mahgfirah

NIM : E0220308

Judul : Analisis *Support Vector Regression* dengan Algoritma *Grid Search Time Series Cross Validation* untuk Meramalkan Saham Pertambangan di Indonesia

Telah berhasil dipertanggungjawabkan di hadapan Tim Penguji (SK Nomor 48/UN55.7/HK.04/2024, tanggal 10 Juli 2024) dan diterima sebagai bagian persyaratan memperoleh gelar Sarjana S1 Statistika pada Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Sulawesi Barat.

Disahkan oleh:

Dekan FMIPA

Universitas Sulawesi Barat



Musafira, S.Si., M.Sc.  
\* NIP. 197709112006042002

Tim Penguji:

Ketua Penguji : Musafira, S.Si., M.Sc.

Sekretaris : Muh. Hijrah, S.Pd., M.Si.

Pembimbing 1 : Hikmah, S.Pd., M.Sc.

Pembimbing 2 : Putri Indi Rahayu, S.Si., M.Stat.

Penguji 1 : Fardinah, S.Si., M.Sc.

Penguji 2 : Muhammad Hidayatullah, S.Pd., M.Kom.

Penguji 3 : Retno Mayapada, S.Si., M.Si.



(.....)  
(.....)  
(.....)  
(.....)  
(.....)  
(.....)  
(.....)

## ABSTRAK

Peramalan adalah kegiatan yang dilakukan untuk memperkirakan apa yang akan terjadi di masa mendatang. Analisis dalam melakukan prediksi dan peramalan data *time series* ini menggunakan metode *support vector regression* (SVR) dengan algoritma *grid search time series cross validation*. SVR merupakan pengembangan dari *Support Vector Machine* (SVM) untuk pendekatan regresi. Penelitian ini bertujuan untuk meramalkan data *time series* saham harian perusahaan pertambangan di Indonesia. Pengujian akurasi model ini menggunakan *Root Mean Square Error* (RMSE), *Mean Square Error* (MSE), *Mean Absolute Percentage Error* (MAPE) dan *R-squared*, dimana model yang memiliki nilai terkecil adalah model terbaik. Hasil penelitian menunjukkan bahwa Model SVR yang diperoleh untuk saham ITMG yaitu SVR dengan *kernel* polinomial dengan parameter  $C = 0,1$ ,  $degree = 1$ ,  $epsilon = 0,01$  dengan akurasi model RMSE sebesar 0,0574; MSE sebesar 0,0033; MAPE sebesar 13,63%; dan *R-Squared* 0,99. Selanjutnya untuk saham ANTAM model SVR yang diperoleh yaitu SVR *kernel* RBF dengan parameter  $C = 100$ ,  $epsilon = 0,01$ ,  $gamma = 0,1$  dengan akurasi model RMSE sebesar 0,0831; MSE sebesar 0,0069; MAPE sebesar 18,49%; dan *R-Squared* 0,99. Kemudian untuk saham DSS model SVR yang diperoleh yaitu SVR *kernel* linear dengan parameter  $C = 100$ ,  $epsilon = 0,01$  dengan akurasi model RMSE sebesar 0,0583; MSE sebesar 0,0034; MAPE sebesar 10,53%; dan *R-Squared* 0,99. Berdasarkan kriteria dari MAPE, didapatkan nilai akurasi untuk masing-masing saham menunjukkan bahwa model dikatakan baik untuk meramalkan ketiga saham pertambangan tersebut. Pada hasil peramalan yang didapatkan untuk ketiga saham cenderung mengalami penurunan.

**Kata Kunci :** *GridSearchCV*, Peramalan, Saham, SVR, *Time Series*

## **ABSTRACT**

*Forecasting is an activity carried out to estimate what will happen in the future. This analysis in predicting and forecasting time series data uses the support vector regression (SVR) method with the grid search time series cross validation algorithm. SVR is the development of Support Vector Machine (SVM) for regression approach. This study aims to forecast the time series data of daily stocks of mining companies in Indonesia. Testing the accuracy of this model uses Root Mean Square Error (RMSE), Mean Square Error (MSE), Mean Absolute Percentage Error (MAPE) and R-squared, where the model that has the smallest value is the best model. The results showed that the SVR model obtained for ITMG shares was SVR with a polynomial kernel with parameters  $C = 0.1$ ,  $\text{degree} = 1$ ,  $\text{epsilon} = 0.01$  with model accuracy RMSE of 0.0574; MSE of 0.0033; MAPE of 13.63%; and R-Squared 0.99. Furthermore, for ANTAM shares, the SVR model obtained is RBF kernel SVR with parameters  $C = 100$ ,  $\text{epsilon} = 0.01$ ,  $\text{gamma} = 0.1$  with RMSE model accuracy of 0.0831; MSE of 0.0069; MAPE of 18.49%; and R-Squared 0.99. Then for DSS stocks, the SVR model obtained is linear kernel SVR with parameters  $C = 100$ ,  $\text{epsilon} = 0.01$  with RMSE model accuracy of 0.0583; MSE of 0.0034; MAPE of 10.53%; and R-Squared 0.99. Based on the criteria of MAPE, the accuracy value for each stock shows that the model is said to be good for forecasting the three mining stocks. In the forecasting results obtained for the three stocks tend to decrease.*

**Keywords :** *GridSearchCV, Forecasting, Stock, SVR, Time Series*

# **BAB I**

## **PENDAHULUAN**

### **1.1. Latar Belakang**

Pasar modal adalah sistem keuangan terorganisir di mana bank komersial dan lembaga keuangan bertindak sebagai perantara sekuritas seperti saham, obligasi, dan obligasi korporasi. Pada hakikatnya pasar modal merupakan sarana yang menghubungkan pihak yang kelebihan dana dan pihak yang membutuhkan dana. Kegiatan pasar modal sebagai salah satu potensi perekonomian nasional yang semakin berperan penting dalam pembangunan perekonomian nasional. Salah satu kelebihan pasar modal adalah memberikan kesempatan kepada masyarakat untuk berpartisipasi dalam kegiatan ekonomi yang diwujudkan dalam bentuk investasi sekuritas. Keberadaan pasar modal juga mendorong investor saham untuk berinvestasi. Salah satu cara mengetahui saham mana yang baik adalah dengan melihat indeks harga saham. Indeks harga saham menjadi indikator penting yang menunjukkan pergerakan harga saham (Sidqi & Prabawani, 2017).

Saham adalah produk pasar investasi yang paling populer. Penerbitan saham merupakan salah satu strategi yang dilakukan suatu perusahaan atau badan usaha untuk menambah modal perusahaan (BEI, 2024). Di sisi lain, saham juga menjadi investasi pilihan banyak investor karena menawarkan *return* yang menarik. Ketika memasukkan modal atau investasi ekuitas, investor menerima klaim yang sah atas aset dan pendapatan perusahaan. Berinvestasi pada saham juga dapat mengakibatkan kerugian bagi investor karena perkembangannya yang dinamis dan tren yang tidak menentu (Yudhawan, 2020).

Harga saham yang dinamis, cenderung membuat para investor memiliki pandangan yang berbeda satu sama lain akan sebuah saham sehingga tidak jarang hal ini menyebabkan seorang investor ragu untuk membeli, menjual atau mempertahankan saham. Prediksi pasar saham merupakan salah satu isu penting dalam bidang *stock trading*, dan prediksi harga bervariasi bergantung pada waktu dan informasi masa lalu. Hal ini digunakan untuk menentukan nilai masa depan saham perusahaan atau instrumen keuangan lainnya yang diperdagangkan di bursa

keuangan. Hasil prediksi pasar saham yang akurat digunakan karena berbagai alasan, terutama kebutuhan investor untuk melindungi nilai terhadap potensi risiko pasar dan peluang bagi spekulator pasar dan arbitrase menghasilkan keuntungan melalui perdagangan indeks (Yudhawan, 2020). Oleh karena itu, investor harus berhati-hati dalam berinvestasi saham.

Bursa Efek Indonesia (BEI) merupakan lembaga pasar modal yang didirikan melalui penggabungan Bursa Efek Jakarta (BEJ) dan Bursa Efek Surabaya (BES). Misi utama BEI adalah mengelola transaksi sekuritas di pasar modal Indonesia, khususnya di sektor ekuitas. BEI membagi sahamnya ke dalam 9 sektor usaha, termasuk sektor pertambangan. Sektor pertambangan merupakan sektor utama sebagai penghasil bahan baku. Sektor pertambangan sendiri menopang perekonomian nasional dan ketahanan energi nasional, baik dari segi penyerapan tenaga kerja maupun perolehan devisa dari ekspor. Sektor pertambangan terbagi menjadi lima subsektor, salah satunya adalah subsektor pertambangan batubara. Subsektor pertambangan batubara saat ini menyumbang 75-80 persen Penerimaan Negara Bukan Pajak (PNBP) sektor mineral dan batubara (Yudhawan, 2020).

Peramalan harga saham merupakan metode analisis yang menghitung harga saham di masa depan berdasarkan informasi harga saham di masa lalu. Peramalan harga saham sangat berguna bagi investor yang membeli dan menjual saham. Teknik ini bertujuan untuk menghindari kerugian akibat sifat harga saham yang sewaktu-waktu dapat berfluktuasi dan dinamis. Oleh karena itu, peramalan harga saham diperlukan untuk memaksimalkan *return* investor. Pada prinsipnya peramalan dapat dilakukan dengan berbagai cara, namun karena karakteristik data inventaris merupakan data *time series* yang terus berubah seiring berjalannya waktu, maka penggunaan model *time series* memberikan metode peramalan yang baik dan optimal (Rahmadayanti dkk., 2018). Salah satu metode yang dapat digunakan untuk memprediksi dan meramalkan pergerakan harga saham adalah *machine learning* (ML).

Kemampuan mesin untuk belajar tanpa instruksi atau pemrograman sebelumnya disebut *machine learning* (Samuel, 2000). Secara umum, ada dua jenis *machine learning* yaitu *supervised learning* dan *unsupervised learning*. Keunikan

dari *machine learning* adalah adanya proses pelatihan dan pembelajaran sehingga memerlukan data untuk dipelajari dan data untuk diuji (Abu Ahmad, 2017). Salah satu contoh algoritma *supervised learning* adalah *Support Vector Machine*.

Algoritma *Support Vector Machine* yang disingkat SVM adalah algoritma *supervised learning* yang berbentuk klasifikasi dengan menggunakan garis *vector* yang disebut *hyperplane* untuk membagi data menjadi dua kelas. Modifikasi SVM yang digunakan untuk pendekatan regresi adalah *Support Vector Regression* atau yang disingkat dengan SVR. Konsep dari SVR adalah memaksimalkan *hyperplane* untuk mendapatkan data-data *support vector*. Yasin dkk. (2014) meneliti tentang prediksi harga saham menggunakan *support vector regression* dengan algoritma *grid search*. Pada penelitian ini membahas prediksi harga saham PT XL Axiata Tbk menggunakan *support vector regression* dengan penentuan model terbaik menggunakan algoritma *grid search*. Didapatkan hasil *kernel* terbaik yaitu pada fungsi *kernel linear* dengan parameter  $C = 0,1$  dan  $\epsilon = 0,1$ . Model yang didapatkan mempunyai tingkat akurasi sebesar 92,47% untuk data *training* dan tingkat akurasi sebesar 83,39% untuk data *testing*. Namun Penelitian ini belum menyertakan validasi silang yang memadai, sehingga hasil prediksi mungkin kurang akurat atau rentan terhadap *overfitting* dan interpretasi hasilnya kurang mendetail.

Penelitian selanjutnya yaitu dari Ramdhani & Mubarak (2019), dimana penulis ini meneliti tentang analisis *time series* prediksi penutupan harga saham ANTAM.JK dengan algoritma SVM model regresi. Didapatkan hasil nilai RMSE dari algoritma SVM sebesar 22,662 sehingga tidak optimal, maka dioptimalkan menggunakan optimasi parameter sehingga didapatkan nilai RMSE terendah sebesar 10,495. Hasil tersebut dapat disimpulkan baik untuk prediksi saham menggunakan algoritma SVM dengan optimasi parameter menggunakan algoritma genetika. Penelitian tersebut berfokus pada pengoptimasian parameter untuk memprediksi harga saham. Penelitian ini menggunakan data dengan rentang waktu yang relatif singkat, sehingga hasilnya mungkin tidak mencerminkan tren jangka panjang.

SVM banyak digunakan untuk prediksi dan peramalan harga saham dan menunjukkan kinerja yang lebih baik dibandingkan algoritma lain termasuk *Artificial Neural Network* atau yang biasa disingkat ANN. *Artificial Neural Network* telah banyak digunakan dalam proses peramalan selama beberapa waktu sebagai alternatif yang optimal dalam peramalan harga saham. *Artificial Neural Network* menemukan solusi secara lokal optimal. Namun, SVM menemukan solusi global yang lebih unggul (Santosa dalam Yudhawan, 2020).

Berdasarkan uraian latar belakang yang telah dipaparkan tersebut, maka penulis ingin melakukan penelitian mengenai peramalan harga saham ITMG, ANTAM, dan DSS menggunakan metode *Support Vector Regression* (SVR). Penelitian ini menggunakan harga penutupan saham perusahaan pertambangan yang diambil dari *yahoo finance* periode 01 Januari 2019 sampai 10 Juli 2024 yang terdiri dari PT Indo Tambangraya Megah Tbk (ITMG.Jk), PT Aneka Tambang Tbk (ANTAM.Jk), dan PT Dian Swastatika Sentosa Tbk (DSS.Jk). Ketiga perusahaan tersebut diantaranya bergerak pada bidang pertambangan batubara.

### **1.2. Rumusan Masalah**

Berdasarkan latar belakang permasalahan yang ada maka didapatkan rumusan masalah yang dapat diidentifikasi dalam tugas akhir ini adalah sebagai berikut:

1. Bagaimana model terbaik yang didapatkan menggunakan metode SVR untuk memprediksi harga saham ITMG, ANTAM dan DSS?
2. Bagaimana hasil peramalan harga saham ITMG, ANTAM, dan DSS untuk 30 hari selanjutnya menggunakan metode SVR?

### **1.3. Tujuan Penelitian**

Tujuan dari penelitian ini adalah sebagai berikut:

1. Mengetahui model terbaik menggunakan metode SVR untuk memprediksi harga saham ITMG, ANTAM dan DSS.
2. Mengetahui hasil peramalan harga saham ITMG, ANTAM, dan DSS untuk 30 hari selanjutnya menggunakan metode SVR.



#### **1.4. Manfaat Penelitian**

Adapun manfaat dari penelitian ini sebagai berikut:

1. Sebagai pedoman dalam berinvestasi guna memprediksi naik turunnya harga saham.
2. Mengetahui sejauh mana keakuratan metode SVR untuk memprediksi harga saham.

#### **1.5. Batasan Masalah**

Adapun batasan masalah dalam penelitian ini yaitu data yang digunakan merupakan data historis saham harian periode Januari 2019 hingga Juli 2024 yang diambil dari *website yahoo finance*. Metode yang digunakan yaitu SVR dengan bantuan *software python* dan *Microsoft Excel*. Metode SVR menggunakan nilai parameter  $C = 0,01; 0,1; 1; 10; 100$ ;  $\epsilon = 0,01; 0,1; 1; 10; 100$ ;  $\text{degree} = 0, 1, 2, 3, 4$ , dan  $\text{gamma} = 0,1; 1; 10; 100$ . Pada penelitian ini menggunakan *kernel Linear*, *kernel Polinomial*, *kernel Radial Basic Function* (RBF) dan *kernel Sigmoid*.

## BAB II TINJAUAN PUSTAKA


### 2.1 *Data Time Series*

Data deret waktu (*Time Series*) adalah tipe data yang terdiri dari variabel-variabel yang disusun menurut urutan waktu dalam rentang tertentu. Data deret waktu juga dapat berdurasi harian, mingguan, bulanan, atau tahunan. Contoh data *time series* pada sektor pertanian, produksi pertanian tahunan, dan harga pertanian tahunan. Pada sektor ekonomi menggunakan harga saham bulanan, suku bunga bulanan, indeks harga bulanan, penjualan tahunan, dan pendapatan tahunan. Keuntungan data deret waktu adalah memungkinkan untuk melihat pola data historis dan proyeksi untuk menginformasikan keputusan perencanaan di masa depan (Yudhawan, 2020).

Keputusan penting dalam memilih suatu metode *time series* yang tepat ialah dengan mempertimbangkan jenis pola data, sehingga metode yang paling tepat dengan pola tersebut dapat diuji. Menurut Makridakis, S., & Wheelwright, S dalam Wardani (2017), pola data dapat dibedakan menjadi empat jenis pola data, yaitu:

#### 1. Pola Horizontal (H)

Dikatakan pola horizontal jika nilai data berfluktuasi didaerah nilai rata-rata yang konstan. Data seperti itu “stasioner” terhadap nilai rata-ratanya. Suatu perusahaan yang penjualan produknya tidak meningkat atau menurun dalam waktu tertentu termasuk jenis pola data ini. Bentuk pola horizontal dapat dilihat pada gambar berikut:




Sumber : (fariadpradhana, 2012)

**Gambar 2.1. Pola data horizontal**

## 2. Pola Musiman (S)

Dikatakan pola musiman jika suatu deret dipengaruhi oleh faktor musiman, seperti kuartal tahunan tertentu, bulanan, atau hari-hari pada pekan tertentu. Penjualan dari produk seperti es krim, minuman ringan, dan bahan bakar pemanas ruangan menunjukkan jenis pola data ini. Bentuk pola musiman dapat dilihat pada gambar berikut:




Sumber : (fariedpradhana, 2012)

**Gambar 2.2. Pola data musiman**

## 3. Pola Siklis (C)

Dikatakan pola siklis jika datanya dipengaruhi oleh fluktuasi ekonomi jangka panjang seperti yang berhubungan dengan siklus bisnis. Penjualan produk seperti mobil, baja dan peralatan utama lainnya menunjukkan jenis pola data ini. Bentuk pola data siklis dapat dilihat pada gambar berikut:




Sumber : (fariedpradhana, 2012)

**Gambar 2.3. Pola data siklis**

## 4. Pola *Trend* (T)

Dikatakan pola *trend* jika terdapat kenaikan atau penurunan sekuler jangka panjang dalam data. Contohnya penjualan produk suatu perusahaan, Produk Bruto Nasional (GNP) dan berbagai indikator bisnis atau ekonomi lainnya mengikuti

suatu pola *trend* selama perubahannya dari waktu ke waktu dalam jangka waktu yang panjang. Bentuk pola *trend* dapat dilihat pada gambar berikut:



Sumber : (fariedpradhana, 2012)

**Gambar 2.4. Pola data *trend***

## 2.2 Peramalan (*Forecasting*)

Peramalan adalah cara yang dilakukan memperkirakan apa yang akan terjadi di masa mendatang. Peramalan terjadi karena ada jeda waktu antara persepsi kejadian atau kebutuhan masa depan dan kejadian itu sendiri. Peramalan perlu dilakukan untuk menentukan apakah suatu peristiwa akan terjadi dimasa depan, sehingga dapat diambil tindakan yang tepat. Peramalan merupakan alat penting untuk perencanaan yang efektif dan efisien. Ada dua pendekatan untuk peramalan, yakni pendekatan kualitatif dan pendekatan kuantitatif.

Menurut Herjanto (2008), peramalan dibedakan menjadi beberapa jenis berdasarkan waktunya yaitu:

1. Peramalan jangka panjang adalah ramalan yang berlangsung lebih dari 18 bulan.
2. Peramalan jangka menengah adalah ramalan untuk jangka waktu 3 hingga 18 bulan.
3. Peramalan jangka pendek adalah ramalan dengan jangka waktu kurang dari 3 bulan.

## 2.3 Analisis Deskriptif

Analisis deskriptif adalah metode analisis data yang digunakan untuk menggambarkan, meringkas, dan menginterpretasikan data dalam bentuk yang

mudah dipahami. Metode ini tidak membuat kesimpulan tentang populasi yang lebih besar atau menjelaskan hubungan sebab-akibat, melainkan fokus pada penyajian karakteristik utama dari kumpulan data. Analisis deskriptif penting karena memberikan gambaran awal tentang data dan membantu dalam mengidentifikasi pola atau anomali yang mungkin ada. Ini juga merupakan langkah awal yang penting sebelum melakukan analisis yang lebih kompleks, seperti analisis inferensial atau analisis regresi.

Dalam jenis penelitian kuantitatif, analisis statistik deskriptif direkomendasikan sebagai langkah pertama sebelum melakukan analisis data lebih lanjut. Karena analisis statistik deskriptif memungkinkan kita mengidentifikasi dengan cepat data yang kita kumpulkan untuk analisis selanjutnya. Selain itu, ini juga dapat menyederhanakan dan meminimalkan hasil analisis pada analisis lainnya (Maswar, 2017).


#### **2.4 *Machine learning***

*Machine learning* (ML) adalah sub-bidang dari kecerdasan buatan (*Artificial Intelligence* (AI)) yang berfokus pada pengembangan algoritma dan teknik yang memungkinkan komputer untuk belajar dari masa lalu dan membuat prediksi atau keputusan berdasarkan data. Algoritma dalam *machine learning* digunakan untuk menganalisis data, menemukan pola, dan membuat model yang dapat digunakan untuk membuat prediksi atau mengambil tindakan berdasarkan data baru. Menurut Vishwakarma (2024), tujuan dari *machine learning* adalah untuk belajar dari data. Banyak penelitian telah dilakukan tentang bagaimana membuat mesin belajar dengan sendirinya tanpa diprogram secara eksplisit.

#### **2.5 *Support Vector Machine***

Dalam *machine learning*, *support vector machine* (SVM) adalah model pembelajaran yang diawasi dengan algoritma pembelajaran terkait dengan menganalisis data yang digunakan untuk klasifikasi dan analisis regresi. Selain melakukan klasifikasi *linear*, SVM dapat secara efektif melakukan klasifikasi nonlinier menggunakan yang disebut fungsi *kernel*, yang secara implisit memetakan masukannya ke dalam ruang fitur berdimensi tinggi. Pada dasarnya, ini

menarik *margin* diantara beberapa kelas. *Margin* dibuat sedemikian rupa sehingga jarak antara *margin* dan kelas dimaksimalkan dan dengan demikian kesalahan klasifikasi dapat diminimalisir (Vishwakarma, 2024). Secara sederhana, konsep SVM berusaha mencari *hyperlane* terbaik yang berfungsi memisahkan dua kelas data yang berbeda secara maksimal pada ruang *input*.



Sumber : (MB Herlambang, 2018)

**Gambar 2.5. Ilustrasi konsep SVM**

Berdasarkan gambar 2.5, terlihat beberapa pola yang merupakan anggota dari 2 kelas yaitu data positif (+1) dan negatif (-1). Data pada kelas positif (+1) disimbolkan dengan bentuk lingkaran hitam penuh, sedangkan kelas negatif (-1) disimbolkan dengan bentuk lingkaran putih. *Hyperplane* atau batas pemisah terbaik antara kedua kelas dapat ditentukan dengan mengukur *margin hyperplane* tersebut dan mencari titik maksimalnya. *Margin* adalah jarak antara *hyperplane* dengan data terdekat dari masing-masing kelas. Data yang paling dekat ini disebut *support vector*. Garis solid menunjukkan *hyperplane* terbaik, karena terletak tepat ditengah-tengah kedua kelas. Sedangkan data bujur sangkar dan lingkaran yang dilewati garis batas *margin* (garis putus-putus) adalah *support vector*.

Misalkan data yang terdapat pada himpunan data latih dinotasikan sebagai  $x_i \in \mathbb{R}^d$  dan label kelas sebagai  $y_i \in \{-1, +1\}$  untuk  $i = 1, 2, 3, \dots, n$ , dimana  $n$  adalah jumlah data. Menurut Wang dalam Elsa (2023), persamaan model SVM linier untuk menghasilkan *hyperplane* sebagai berikut:

$$y_i = w \cdot x_i + b \quad (2.1)$$

dengan:

$y_i$  = Nilai target himpunan data

$w$  = Vektor parameter pembobot


$x_i$  = Vektor variabel bebas, dengan  $i = 1, 2, \dots, n$

$b$  = Bias

$n$  = Jumlah data

## 2.6 *Support Vector Regression*

Masalah regresi adalah generalisasi dari masalah klasifikasi, di mana model mengembalikan *output* bernilai kontinu, bukan *output* dari himpunan yang terbatas. Dengan kata lain, model regresi mengestimasi fungsi multivariat bernilai kontinu. SVM memecahkan masalah klasifikasi biner dengan merumuskannya sebagai masalah optimasi cembung (Kurniawati, 2017). Masalah optimasi ini membutuhkan pencarian *margin* maksimum yang memisahkan *hyperplane*, sambil mengklasifikasikan sebanyak mungkin titik pelatihan dengan benar. SVM merepresentasikan *hyperplane* optimal ini dengan vektor pendukung. Solusi yang jarang dan generalisasi yang baik dari SVM memungkinkan untuk diadaptasi untuk masalah regresi. Generalisasi SVM ke SVR dilakukan dengan memperkenalkan wilayah *e-insensitive* di sekitar fungsi, yang disebut *e-tube*. Tabung ini merumuskan ulang masalah optimasi untuk menemukan tabung yang paling mendekati fungsi bernilai kontinu, sambil menyeimbangkan kompleksitas model dan kesalahan prediksi. Secara lebih spesifik, SVR diformulasikan sebagai masalah optimasi dengan terlebih dahulu mendefinisikan fungsi kerugian *e-insensitive* cembung yang akan diminimalkan dan menemukan tabung paling datar yang berisi sebagian besar contoh pelatihan. Oleh karena itu, sebuah fungsi multiobjektif dibangun dari fungsi kerugian dan sifat geometris tabung (Kurniawati, 2017).



Sumber : (MB Herlambang, 2018)

### Gambar 2.6 Ilustrasi konsep SVR

Pada gambar 2.6, garis tengah merupakan *hyperplane* sedangkan untuk dua garis yang mengapitnya adalah *soft margin*. Jarak antara *hyperplane* dan *soft margin* adalah sebesar  $\varepsilon$  dan titik-titik yang berada pada  $+\varepsilon$  sampai  $-\varepsilon$  merupakan *support vector*, namun untuk titik yang mewakili *soft margin* dibutuhkan adanya variabel slack  $\xi$ .

Konsep dasar penggunaan SVR adalah misalkan terdapat  $n$  set data *training*,  $(x_i, y_i)$  dengan  $x_i \in \mathbb{R}^d$  adalah *vector input* dari data ke  $-i$  dimana  $i = 1, 2, 3, \dots, n$ , dan  $d$  adalah dimensi dan  $y_i$  adalah nilai target. Persamaan fungsi regresi secara umum dapat ditulis sebagai berikut (Smola & Scholkopt dalam Elsa, 2023):

$$f(x) = \langle w \cdot x \rangle + b \quad (2.2)$$

dengan:

$f(x)$  = Fungsi SVR

$x$  = Vektor *Input*

$w$  = Vektor pembobot berdimensi  $l$

$b$  = Bias

Persamaan (2.2) merupakan fungsi *linear* secara umum, dimana  $\langle \rangle$  adalah *dot product* (hasil kali) di  $x$ . Agar mendapatkan generalisasi yang baik pada fungsi  $f(x)$  maka dapat dilakukan dengan meminimalkan  $w$  dengan penyelesaian masalah optimasi sebagai berikut:

$$\min \frac{1}{2} \|w\|^2 \quad (2.3)$$



dengan syarat:

$$y_i - \langle w \cdot x_i \rangle - b \leq \varepsilon$$

$$\langle w \cdot x_i \rangle - y_i + b \leq \varepsilon$$

$\varepsilon = \text{Margin}$

Diasumsikan pada persamaan (2.3) semua titik berada pada rentang  $f(x) \pm \varepsilon$ . Diperbolehkan ada kondisi dimana melebihi ambang nilai  $\varepsilon$ , akibat kemungkinan titik-titik keluar dari rentang  $f(x) \pm \varepsilon$ . Pada kondisi ini dibutuhkan *soft margin* atau variabel *slack*  $\xi_i + \xi_i^*$  sehingga persamaannya berubah menjadi:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (2.4)$$

dengan syarat:

$$y_i - \langle w \cdot x_i \rangle - b \leq \varepsilon + \xi_i$$

$$\langle w \cdot x_i \rangle - y_i + b \leq \varepsilon + \xi_i^*$$

$$\xi_i + \xi_i^* \geq 0$$

$C$  = Cost (pinalti atas kesalahan pelatihan)

$\xi_i \xi_i^*$  = Variabel *slack*

Konstanta  $C$  pada persamaan (2.4) dimana  $C > 0$  merupakan nilai pinalti akibat pelanggaran toleransi terhadap fungsi  $f(x)$  dan seberapa besar tingkat deviasi kesalahan dari batas  $\varepsilon$  yang dapat ditoleransi. Semua nilai yang lebih besar dari  $\varepsilon$  akan dipinalti sebesar  $C$ . Hal ini disebut dengan  $\varepsilon$ -insensitive loss function  $|\xi|_\varepsilon$ .

$$|\xi|_\varepsilon = \begin{cases} 0 & ; \text{jika } |\xi| \leq \varepsilon \\ |\xi| - \varepsilon & ; \text{lainnya} \end{cases} \quad (2.5)$$

Nilai  $\varepsilon$  yang kecil berkaitan dengan nilai yang tinggi pada variabel *slack* dan akurasi aproksimasi yang tinggi. Sebaliknya, nilai yang tinggi untuk  $\varepsilon$  berkaitan dengan nilai variabel *slack* yang lebih kecil dan membuat akurasi menjadi lebih

rendah. Nilai *slack* yang tinggi dapat mengakibatkan kesalahan empiris pada perhitungan.

Penentuan nilai parameter  $w$  dan  $b$  menjadi masalah pemrograman kuadratik (*quadratic programming*), yaitu meminimumkan suatu fungsi kuadrat dengan syarat suatu pertidaksamaan *linear*. Persoalan ini akan mudah diselesaikan menggunakan *Lagrange Multiplier*. Solusi optimal untuk persamaan (2.4) dengan pembatas pada persamaan (2.5) dapat dipecahkan dengan persamaan *Lagrange Multiplier* sebagai berikut:

$$L = \left( \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \right) - \left( \sum_{i=1}^l \alpha_i (\varepsilon + \xi_i - y_i + \langle w, x \rangle + b) \right) - \left( \sum_{i=1}^l \alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle w, x \rangle - b) \right) - \left( \sum_{i=1}^l (\eta_i \xi_i + \eta_i^* \xi_i^*) \right) \quad (2.6)$$

dengan:

$L$  = Fungsi *Lagrange*

$\alpha_i, \alpha_i^*$  = *Lagrange Multiplier* (koefisien *lagrange*)

Dimana untuk mendapatkan solusi yang optimal, maka dilakukan turunan parsial dari  $L$  terhadap  $w, b, \xi_i, \xi_i^*$ .

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i = 0 \quad (2.7)$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0 \quad (2.8)$$

$$\frac{\partial L}{\partial \xi_i} = \sum_{i=1}^l (C - \alpha_i - \eta_i) = 0 \quad (2.9)$$

$$\frac{\partial L}{\partial \xi_i^*} = \sum_{i=1}^l (C - \alpha_i^* - \eta_i^*) = 0 \quad (2.10)$$

dengan mensubstitusi persamaan (2.7), (2.8), (2.9) dan (2.10) ke persamaan (2.6) maka diperoleh

$$\max \begin{cases} -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) (x_i \cdot x_j) \\ -\varepsilon \sum_{i=1}^l (\alpha_i - \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \end{cases} \quad (2.11)$$

dengan syarat:

$$\sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0$$

$$0 \leq \alpha_i \leq C \quad \forall_i = 1, 2, \dots, n$$

$$0 \leq \alpha_i^* \leq C \quad \forall_i = 1, 2, \dots, n$$

Dari proses penurunan rumus pada persamaan (2.11) didapatkan variabel utama yaitu  $\alpha_i$  dan  $\alpha_i^*$ . Dari persamaan (2.7) didapatkan persamaan sebagai berikut:

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i \quad (2.12)$$

Selanjutnya untuk permasalahan komputasi nilai  $b$  dapat dimaksimalkan dari kondisi

$$\begin{aligned} \alpha_i (\varepsilon + \xi_i - y_i + \langle w, x \rangle + b) &= 0 \\ \alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle w, x \rangle - b) &= 0 \end{aligned} \quad (2.13)$$

dan

$$\begin{aligned} (C - \alpha_i) \xi_i &= 0 \\ (C - \alpha_i^*) \xi_i^* &= 0 \end{aligned} \quad (2.14)$$

Berdasarkan persamaan (2.14) didapatkan  $C = \alpha_i$ , maka nilai  $w$  dihitung bergantung dengan nilai *support vector*. Selanjutnya mensubsitusikan persamaan (2.2) dan persamaan (2.12) sehingga didapat persamaan baru sebagai berikut:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \langle x_i, x_j \rangle + b \quad (2.15)$$

Persamaan (2.12) merupakan persamaan yang digunakan untuk menghitung persamaan secara *linear*. Sedangkan untuk permasalahan *nonlinear* nilai  $x_i$  dan  $x_j$  terlebih dahulu harus ditransformasikan ke dalam *feature space* dengan cara memetakan vector  $x_i$  dan  $x_j$  ke dalam fungsi  $\Phi$  yaitu  $\Phi: \mathbb{R} \rightarrow \mathbb{R}^z$  menghasilkan persamaan sebagai berikut:

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \phi(x_i) \quad (2.16)$$

Sehingga didapatkan persamaan sebagai berikut:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \phi(x_i) \phi(x_j) + b \quad (2.17)$$

Karena *input vector*  $x_i$  dan  $x_j$  sudah ditransformasikan oleh fungsi  $\phi$  dan sudah berada dalam *feature space*, maka fungsi transformasi  $\phi$  dapat direpresentasikan dengan fungsi *kernel*  $K$  sebagai berikut:

$$K(x_i, x_j) = \phi(x_i) \phi(x_j) \quad (2.18)$$

Maka didapatkan persamaan akhir sebagai berikut:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (2.19)$$

Fungsi  $K(x_i, x_j)$  adalah fungsi *kernel* yang sering digunakan dalam metode SVM maupun SVR.

## 2.7 Fungsi Kernel

Secara umum, dalam konteks komputer dan sistem operasi, *kernel* mengacu pada inti atau bagian terpenting dari sistem. *Kernel* dapat ditemukan di bidang yang berbeda, termasuk sistem operasi, pemrosesan sinyal, matematika, dan ilmu data. Dalam matematika, fungsi *kernel* adalah fungsi yang memetakan vektor *input* ke ruang dimensi yang lebih tinggi. Fungsi *kernel* digunakan dalam berbagai algoritma *machine learning* seperti SVM dan SVR. Untuk membantu mengatasi permasalahan *nonlinear* pada dimensi tinggi yang dilakukan yaitu mengganti *linear product* ( $x_i$  dan  $x_j$ ) dengan fungsi *kernel*. Karena kinerja dari metode SVR ditentukan oleh jenis fungsi *kernel* dan parameter yang digunakan. Berikut adalah beberapa fungsi dan peran *kernel* dalam SVR:

Tabel 2.1. Fungsi *kernel*

No	Tipe <i>Kernel</i>	Formula	Kegunaan
1	<i>Linear</i>	$K(x_i, x_j) = (x_i x_j)$	Digunakan saat data dapat dipisahkan secara <i>linear</i> . <i>Kernel</i> paling sederhana dan cepat untuk dihitung
2	Polinomial	$K(x_i, x_j) = (x_i x_j + 1)^P$	Memungkinkan pemetaan ke ruang fitur polinomial, sehingga memungkinkan hubungan <i>nonlinear</i> dari derajat tertentu. Parameter <i>P</i> menentukan derajat polinomial.
3	Fungsi Radial Basis	$K(x_i, x_j) = \exp(-\gamma(x_i - x_j)^2)$	<i>Kernel</i> yang sangat populer dan mampu menangkap hubungan <i>nonlinear</i> kompleks dengan mengubah data ke ruang dimensi yang lebih tinggi. Parameter $\gamma$ mengontrol lebar <i>kernel</i> .
4	<i>Sigmoid</i>	$K(x_i, x_j) = \tanh(\alpha x_i x_j + c)$	Mirip dengan fungsi aktivasi dalam jaringan saraf, sering digunakan dalam konteks yang mirip dengan RBF.

dengan:

$x_i, x_j$  = Vektor dari dua data set

$P$  = Derajat polinomial

$\gamma$  = *Gamma*

## 2.8 *Grid Search Time Series*

*Grid search* adalah metode pencarian *hyperparameter* yang digunakan untuk mengidentifikasi kombinasi parameter terbaik untuk model *machine learning*. Dalam konteks *time series* (deret waktu), penerapan *grid search* sedikit berbeda karena harus memperhitungkan sifat temporal dari data. *Grid search* adalah pemilihan kombinasi model dan *hyperparameter* dengan menguji kombinasi satu per satu dan memvalidasi setiap kombinasi. Tujuan dari *grid search* adalah untuk menentukan kombinasi yang menghasilkan kinerja model terbaik yang dapat

dipilih untuk digunakan sebagai model prediksi (GSK Ranjan dalam Toha dkk., 2022).

## 2.9 Cross Validation

Metode *Cross Validation* digunakan untuk mengevaluasi dan membandingkan algoritma pembelajaran. Metode ini membagi data menjadi 2 bagian, satu data digunakan untuk mempelajari dan melatih model, kemudian data yang lainnya digunakan untuk memvalidasi model.

Bentuk umum dari *cross-validation* adalah *k-fold cross-validation*. *K-fold cross-validation* membagi data menjadi k kelompok dengan ukuran yang sama. Setiap iterasi dari satu atau lebih algoritma mempelajari satu, dua, atau tiga model dengan menggunakan data k-1 dan kemudian menggunakan model yang dipelajari untuk membuat prediksi pada lipatan data validasi (Fahrusyian, 2019).

Kinerja setiap algoritma pembelajaran pada setiap lipatan dapat diukur dengan menggunakan akurasi. Kini *cross-validation* digunakan secara luas pada penelitian terkait data mining dan *machine learning*, serta berfungsi sebagai prosedur standar untuk mengestimasi kinerja dan pemilihan model (Fahrusyian, 2019).

## 2.10 Normalisasi Data

Normalisasi data *time series* adalah proses mengubah skala data agar memiliki distribusi atau *range* yang seragam. Normalisasi membantu model *machine learning* untuk konvergen lebih cepat dan bisa memberikan performa yang lebih baik. Salah satu teknik normalisasi yang sering digunakan adalah *Standardization (Z-score normalization)*.

### 1. *Standardization (Z-Score Normalization)*

*Standardization* mengubah data sehingga memiliki *mean* 0 dan standar deviasi 1. Rumusnya adalah:

$$x_{\text{Standardized}} = \frac{x - \mu}{\sigma} \quad (2.20)$$

Dimana:

$x$  adalah nilai asli.

$\mu$  adalah *mean* dari data asli.

$\sigma$  adalah standar deviasi dari data asli.

### 2.11 Denormalisasi Data

Denormalisasi data adalah proses mengembalikan data yang telah dinormalisasi ke skala aslinya. Hal ini penting dilakukan ketika kita ingin menginterpretasikan hasil model dalam skala aslinya atau saat membandingkan prediksi dengan data asli. Metode denormalisasi bergantung pada jenis normalisasi yang digunakan sebelumnya, untuk melakukan denormalisasi ada dua cara, yaitu *Min-Max Scaling* dan *Z-score Normalization (Standardization)*.

#### 1. *Standardization (Z-Score Normalization)*

Jika data telah dinormalisasi menggunakan *Z-score Normalization*, maka rumus untuk denormalisasi adalah:

$$x = x_{Standardized} \times \sigma + \mu \quad (2.23)$$

Dimana:

$x$  adalah nilai asli.

$x_{Standardized}$  adalah nilai yang telah dinormalisasi.

$\mu$  adalah *mean* dari data asli.

$\sigma$  adalah standar deviasi dari data asli.

### 2.12 Metrik Kinerja SVR

Metrik kinerja SVR adalah alat ukur yang digunakan untuk mengevaluasi seberapa baik model SVR memprediksi nilai target. Berbeda dengan model klasifikasi yang menggunakan metrik seperti akurasi dan *precision*, model regresi seperti SVR menggunakan metrik yang mengukur kesalahan prediksi pada nilai *kontinu*. Berikut adalah penjelasan tentang metrik kinerja yang umum digunakan untuk SVR:

#### 1. *Mean Squared Error (MSE)*

*Mean Squared Error* mengukur rata-rata kuadrat dari kesalahan antara nilai yang sebenarnya dengan nilai yang diprediksi. Ini memberikan gambaran tentang besarnya kesalahan dan lebih sensitif terhadap kesalahan besar karena kesalahan dikuadratkan.

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (2.24)$$

2. Root Mean Squared *Error* (RMSE)

*Root Mean Squared Error* adalah akar kuadrat dari MSE. Ini memberikan interpretasi yang lebih langsung dalam skala yang sama dengan nilai target, dan sensitif terhadap kesalahan besar.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (2.25)$$

3. *R-Squared* ( $R^2$ )

*R-Squared* mengukur seberapa baik nilai yang diprediksi mendekati nilai sebenarnya. Ini mengukur proporsi varians dari nilai target yang dapat dijelaskan oleh model. Nilai  $R^2$  berkisar antara 0 dan 1, dimana 1 menunjukkan model yang sempurna.

$$R^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_i)^2} \quad (2.26)$$

4. *Mean Absolute Percentage Error* (MAPE)

*Mean Absolute Percentage Error* mengukur rata-rata kesalahan absolut sebagai persentase dari nilai sebenarnya. Ini memberikan gambaran tentang seberapa besar kesalahan relatif terhadap nilai sebenarnya. Menurut Fahrusyian (2019) ada beberapa kriteria tentang nilai MAPE yaitu:

**Tabel 2.2. Hasil peramalan berdasarkan nilai MAPE**

MAPE	Hasil Peramalan
<10%	Sangat baik
10-20%	Baik
20-50%	Layak/Cukup
>50%	Buruk

Adapun rumusnya sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| \times 100 \quad (2.27)$$



### **2.13 Saham**

Saham adalah surat berharga yang menjadi bukti kepemilikan atau kepentingan atas modal yang ditanamkan investor pada suatu perusahaan. Dengan memiliki saham suatu perusahaan, investor dapat memperoleh dividen, *capital gain*, dan keuntungan *non* finansial lainnya (Pandji Anoraga, 2008). Menurut Tjiptono Darmaji (2011), saham merupakan bukti bahwa seseorang atau agen mempunyai suatu kepentingan kepemilikan pada suatu perusahaan atau perseroan terbatas.

Menurut Alfianti & Sonja (2017), saham merupakan representasi penyertaan atau kepemilikan perseorangan atau badan hukum dalam suatu perusahaan atau perseroan terbatas. Apabila saham diterbitkan di atas kertas strip, berarti perusahaan yang mendistribusikan efek tersebut juga merupakan pemilik kertas tersebut. Menurut Kasmir (2016) saham merupakan surat berharga yang bersifat kepemilikan. Artinya pemegang saham adalah pemilik perusahaan. Semakin banyak saham yang mereka miliki, semakin besar pula kekuasaan yang mereka miliki dalam perusahaan. Keuntungan yang diperoleh dari saham disebut dividen, dan dividen tersebut diputuskan dalam Rapat Umum Pemegang Saham (RUPS).

### **2.14 Harga Saham**

Menurut Azis (2015) harga saham diartikan sebagai harga pasar riil dan merupakan harga yang paling mudah ditentukan karena sesuai dengan harga saham pasar saat ini atau harga saham jika pasar tutup, maka harga penutupan saat itu adalah harga pasar.

Menurut Widodoatmodjo (2009) harga saham merupakan indikasi penyertaan atau kepemilikan seseorang atau organisasi dalam suatu perusahaan dan mencerminkan keputusan pembiayaan, investasi, dan pengelolaan aset. Menurut Agus Sartono (2015) harga saham adalah harga yang ditampilkan di bursa efek pada waktu tertentu dan ditentukan oleh pelaku pasar, yaitu permintaan dan penawaran pasar.

## **BAB V**

### **PENUTUP**

#### **5.1. Kesimpulan**

Berdasarkan penelitian yang telah dilakukan maka diperoleh kesimpulan dan saran sebagai berikut:

1. Metode SVR bisa diterapkan untuk peramalan harga saham ITMG, ANTAM, dan DSS. Model SVR terbaik yang diperoleh untuk saham ITMG yaitu SVR *kernel* polinomial dengan parameter  $C = 0,1$ ;  $degree = 1$ ;  $epsilon = 0,01$  dengan akurasi model RMSE sebesar 0,0574; MSE sebesar 0,0033; MAPE sebesar 13,63%; dan  $R-Squared$  0,99. Selanjutnya untuk saham ANTAM model SVR terbaik yang diperoleh yaitu SVR *kernel* RBF dengan parameter  $C = 100$ ;  $epsilon = 0,01$ ;  $gamma = 0,1$  dengan akurasi model RMSE sebesar 0,0831; MSE sebesar 0,0069; MAPE sebesar 18,49%; dan  $R-Squared$  0,99. Kemudian untuk saham DSS model SVR yang diperoleh yaitu SVR *kernel* *linear* dengan parameter  $C = 100$ ;  $epsilon = 0,01$  dengan akurasi model RMSE sebesar 0,0583; MSE sebesar 0,0034; MAPE sebesar 10,53%; dan  $R-Squared$  0,99.
2. Hasil peramalan harga saham ITMG, ANTAM, dan DSS dengan model terbaik yang didapatkan untuk 30 hari selanjutnya pada ketiga saham cenderung mengalami penurunan.

#### **5.2. Saran**

Jika dikemudian hari terdapat penelitian yang memiliki topik serupa maka penelitian selanjutnya disarankan dapat membandingkan metode yang digunakan dalam peramalan. Disarankan juga untuk melakukan peramalan pada studi kasus yang berbeda, seperti cuaca atau saham di sektor lainnya.

## DAFTAR PUSTAKA

- Ahmad, A., 2017, Mengenal Artificial Intelligence, Machine Learning, & Deep Learning, *Jurnal Teknologi Indonesia*, 1(June), 1–6. <https://amt-it.com/mengenal-perbedaan-artificial-intelligence-machine-learning-deep-learning/>, diakses tgl 26 Juli 2024.
- Alfianti, D., & Sonja, A., 2017, Pengaruh Profitabilitas Terhadap Harga Saham Pada Prusahaan Makanan dan Minuman yang terdaftar Di Bursa Efek Indonesia, *Jurnal Bisnis Indonesia*, 8(1), 45–56.
- Anoraga, P. P. P., 2008, *Pengantar Pasar Modal*, PT. Rineka Cipta, Jakarta.
- Azis, M., Mintarti, S., & Nadir, M., 2015, *Manajemen Investasi*, Deepublish, Yogyakarta.
- BEI., 2024, Saham, IDX. <https://www.idx.co.id/id/produk/saham>, diakses tgl 29 Juni 2024.
- Binekasri, R., 2024, Harga Saham Meroket, BEI Pantau Ketat Perdagangan DSSA, CNBC Indonesia, <https://www.cnbcindonesia.com/market/20240117080336-17-506460/harga-saham-meroket-bei-pantau-ketat-perdagangan-dssa>, diakses tgl 25 Juli 2024
- Darmaji, T. & Fakhruddin, H. M., 2011, *Pasar Modal di Indonesia*, Jakarta : Salemba Empat.
- Dwi, C., 2024, Daftar 17 Saham Termahal di Bursa, Ada yang Tembus Rp 13 Juta per Lot, Cncbindonesia.Com. <https://www.cnbcindonesia.com/market/20240521102935-17-540010/daftar-17-saham-termahal-di-bursa-ada-yang-tembus-rp-13-juta-per-lot>, diakses tgl 25 Juli 2024.
- Elsa., 2023, Penerapan Metode Support Vector Regression (Svr) Menggunakan Kernel Linear, Polinomial, Dan Radial Dengan Grid Search Optimization, *Mi*, 5–24, *Skripsi*, Program Sarjana Matematika, Univ. Lampung, Bandar Lampung.
- Fahrusyian, G. E., 2019, Menggunakan Metode Support Vector Machine Forecasting the Number of Tuberculosis Disease Patients in East Java Region Using, In *Institute teknologi Sepuluh Nopember*.
- Pradhana, F., 2012, FORECASTING (PERAMALAN), Fariedpradhana.Wordpress.Com. <https://fariedpradhana.wordpress.com/2012/06/28/forecasting-peramalan/>, diakses tgl 26 Juli 2024.
- Girsang, Y., 2020, PT Aneka Tambang Tbk Tidak Efisien, Pemegang Saham Merugi, Yossygirsang.Com. <https://www.yossygirsang.com/pt-aneka-tambang-salah-urus-harga-saham-turun-terus/>, diakses tgl 26 Juli 2024.

- Herjanto, E., 2008, *Manajemen Operasi Edisi Ketiga*, Jakarta: Grasindo.
- Herlambang, M. B., 2018, Machine Learning: Support Vector Regression, Megabagus.Id. <https://www.megabagus.id/machine-learning-support-vector-regression/>, diakses tgl 26 Juli 2024.
- Idris, M., 2021, Meroket 3 Kali Lipat Lebih, Ini Rincian Harga Saham ANTM dalam 3 Bulan, Money.Kompas.Com. <https://money.kompas.com/read/2021/01/09/101124626/meroket-3-kali-lipat-lebih-ini-rincian-harga-saham-antm-dalam-3-bulan?page=all>, diakses tgl 25 Juli 2024.
- Kasmir, 2016, *Analisis Laporan Keuangan*, PT. RajaGrafindo Persada, Jakarta.
- Kurniawati, P., 2017, No Title طرفة على ت تغذى جرائم ..الإلا ك تروذي الابد تزازاد, *Universitas Nusantara PGRI Kediri*, 01, 1–7.
- Maswar, M., 2017, Analisis Statistik Deskriptif Nilai UAS Ekonometrika Mahasiswa dengan Program SPSS 23 & Eviews 8.1, *Jurnal Pendidikan Islam Indonesia*, 1(2), 273–292. <https://doi.org/10.35316/jpii.v1i2.54>.
- Rahmadayanti, C., Rabbani, H., & Rohmawati, A. A., 2018, Model GARCH dengan Pendekatan Conditional Maximum Likelihood untuk Prediksi Harga Saham, *Indonesian Journal on Computing (Indo-JC)*, 3(2), 21. <https://doi.org/10.21108/indojc.2018.3.2.223>.
- Ramdhani, Y., & Mubarak, A., 2019, Analisis Time Series Prediksi Penutupan Harga Saham Antm.Jk Dengan Algoritma SVM Model Regresi, *Jurnal Responsif: Riset Sains Dan Informatika*, 1(1), 77–82.
- Samuel, A. L., 2000, Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 44(1–2), 207–219. <https://doi.org/10.1147/rd.441.0206>.
- Sartono, A., 2015, *Manajemen Keuangan, Teori dan Aplikasi*, Universitas Gajah Mada, Yogyakarta.
- Sidqi, F. I., & Prabawani, B., 2017, Analisis Harga Saham dan Volume Perdagangan Saham Sebelum dan Sesudah Melakukan Stock Split, *Jurnal Ilmu Administrasi Bisnis*, 6(1), 44–54.
- Tirta, C., 2020, Emiten Batu Bara Babak Belur di 2019, Adakah harapan di 2020?, Cnbcindonesia.Com. <https://www.cnbcindonesia.com/market/20200402145601-17-149396/emiten-batu-bara-babak-belur-di-2019-adakah-harapan-di-2020>, diakses tgl 25 Juli 2024.
- Toha, A., Purwono, P., & Gata, W., 2022, Model Prediksi Kualitas Udara dengan Support Vector Machines dengan Optimasi Hyperparameter GridSearch CV, *Buletin Ilmiah Sarjana Teknik Elektro*, 4(1), 12–21. <https://doi.org/10.12928/biste.v4i1.6079>.

- Vishwakarma, A., 2024, a Review: Machine Learning Algorithms, *Data Science: Practical Approach with Python & R, January 2019, International Journal of Science and Research*, 162–175. <https://doi.org/10.58532/nbennurch299>.
- Wardani, S. K., 2017, Pemodelan Multivariate Time Series Menggunakan Multi Input Transfer Function untuk Meramalkan Curah Hujan, 1–73, *Skripsi*, Program Sarjana Matematika, Univ. Negeri Semarang, Jawa Tengah.
- Widoatmodjo, S., 2009, *Pasar Modal Indonesia: Pengantar dan Studi Kasus*, Ghalia Indonesia.
- Yasin, H., Prahutama, A., & Utami, T. W., 2014, Prediksi Harga Saham Menggunakan Support Vector Regression Dengan Algoritma Grid Search, *Media Statistika*, 7(1), 29–35. <https://doi.org/10.14710/medstat.7.1.29-35>.
- Yudhawan, D. H., 2020, Implementasi Support Vector Regression Untuk Peramalan Harga Saham Perusahaan Pertambangan di Indonesia, xv–68, *Skripsi*, Program Sarjana Statistika, Univ. Islam Indonesia, Yogyakarta.