

**ANALISIS SUPPORT VECTOR MACHINE (SVM) DALAM PREDIKSI
PERMINTAAN EMAS PERHIASAN**

(Studi Kasus: Permintaan Emas Perhiasan dari Beberapa Negara Tertentu Periode
Tahun 2000-2021)

TUGAS AKHIR



Mita Raehanun

14 611 027

**JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA**

2021

HALAMAN PERSETUJUAN PEMBIMBING

TUGAS AKHIR

Judul

**ANALISIS SUPPORT VECTOR
MACHINE (SVM) DALAM PREDIKSI
PERMINTAAN EMAS PERHIASAN**

(Studi Kasus: Permintaan Emas Perhiasan
dari Beberapa Negara Tertentu Periode
Tahun 2000-2021)

Nama Mahasiswa

:

Mita Raehanun

Nomor Mahasiswa

14611027



Dosen Pembimbing

(Dr. Edy Widodo, S.Si., M.Si)

HALAMAN PENGESAHAN
TUGAS AKHIR
ANALISIS SUPPORT VECTOR MACHINE (SVM) DALAM PREDIKSI
PERMINTAAN EMAS PERHIASAN

(Studi Kasus: Permintaan Emas Perhiasan dari Beberapa Negara Tertentu Periode
Tahun 2000-2021)

Nama Mahasiswa : Mita Raehanun

Nomor Mahasiswa : 14 611 027

TUGAS AKHIR INI TELAH DIUJI PADA

TANGGAL 08 Juni 2021

Nama Penguji

Tanda Tangan

1. Muhammad Hasan Sidiq K.,S.Si.,M.Sc.

2. Mujiati Dwi Kartikasari,S.Si.,M.Sc.

3. Dr. Edy Widodo,S.Si., M.Si

Mengetahui

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Prof. Riyanto, S.Pd.,M.Si.,Ph.D

HALAMAN PERSEMBAHAN

Terimakasih sebesar –besarnya kepada kedua orang tua saya bapak Abul Maad dan Ibu Zuriati, sampai saat ini telah berjuang dan berusaha membiayai dan memberikan apapun keperluan saya selama ini, saya mengucapkan terima kasih yang sebesar-besarnya atas apa yang telah ibu dan bapak berikan kepada saya, terima kasih atas kasih sayang dan do' tulusnya. Maaf karena sampai sekarang belum bisa membalas semua kebaikan yang telah bapak dan ibu berikan selama ini, semoga dengan menyelesaikan skripsi ini bisa membuat ibu dan bapak tersenyum bahagia, saya persembahkan karya tulis ini untuk ibu dan bapak, maaf jika masih banyak kekurangan dalam karya yang saya buat.

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakaatuh

Alhamdulillah hirabbal Alamin puja dan puji syukur kehadiran Allah Subhaanahu Wataala atas rahmat, nikmat dan kasih sayang yang telah dilimpahkan kepada penulis sehingga bisa menyelesaikan tugas akhir dengan studi kasus “Permintaan Emas Perhiasan dari Beberapa Negara Tertentu Periode Tahun 2000-2021”. Sholawat sertasalam kepada Nabi Muhammad SAW, keluarga dan para Sahabat-sahabatnya.

Penulisan karya tulis ini bertujuan untuk mendapatkan gelar sarjana prodi Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia. terselesaikannya skripsi ini tidak lepas dari dukungan dan bantuan ibu dan bapak dosen Statistika dan dukungan keluarga dan sahabat. Pada kesempatan kali ini dengan kerendahan hati penulis mengucapkan banyak terima kasih kepada pihak-pihak yang memberikan bantuan moril maupun materil, baik secara langsung dan tidak langsung dalam menyelesaikan Tugas Akhir ini hingga selesai, terutama kepada:

1. Bapak Prof. Riyanto, S.Pd.,M.Si.,Ph.D selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia, Yogyakarta.
2. Bapak Dr. Edy Widodo,S.Si., M.Si.selaku Kepala Jurusan Statistika dan selaku dosen pembimbing yang sudah membimbing dan memberikan dukungan serta motivasi kepada penulis sehingga bisa menyelesaikan skripsi ini.
3. Bapak Dr. Jaka Nugraha, S.Si.,M.Si, selaku DPA penulis yang selalu memberikan arahan dan bimbingan yang sangat berguna selama proses perkuliahan.
4. Seluruh dosen Statistika Universitas Islam Indonesia yang telah memberikan banyak pengalaman dan ilmu selama proses belajar mengajar selama ini.
5. Kedua orang tua tersayang, Bapak Abdul Maad dan Ibu Zuriati yang selalu mendo'akan dan memberikan semangat, dukungan dan kasih sayangnya.
6. Adik penulis penulis Heni Nuraini dan regina puspa ayudia yang selalu memberikan dukungan dan semangat yang luar biasa selama ini.

7. Sahabat sekaligus kakak paling resek dan tentunya baik Rendi yunanda, dony pratama jaelani yang selalu ada.
8. Sahabat MTS dan MA paoklombok Mutmainnah, Lia Lestari, Riza Widayanti, Iin Mustika HZ, Abdul Fatah, Multazam, Hibby Aspian, Hauriyah, dan Dina Tunjung Sari yang selalu memberikan dukungan, do'a dan semangat.
9. Teman sekaligus sahabat seperjuangan Molidah S, Lira puji A, Welly, Aisyah, Yumu, Novi s, Anissa, Lia, Dian dan Ayu yang selalu memberi semangat dalam menyelesaikan Tugas Akhir ini.
10. Sahabat paling banyak membantu dari awal kuliah sampai saat ini Khirul faridi.
11. Teman-teman kos sumber rejeky khususnya mbak Halimah zaumi, sifaatul Ikwani dan mbak Niken yang selalu menemani dan berbagi cerita suka dan duka selama kuliah.
12. Teman-teman seperjuangan satu bimbingan tugas akhir Fea, Gina, Defi, Attala, Fahri dan semua teman-teman Statistika 2014 yang senantiasa selalu berbagi ilmu, cerita dan pengalaman. Semua pihak yang tidak dapat penyusun sebutkan satu per satu, terima kasih.

Penulis menyadari dalam penyusunan Tugas Akhir ini masih jauh dari kata sempurna, oleh karena itu jika ada keritikan dan saran yang sifatnya membangun akan penulis terima. Semoga karya ini bisa bermanfaat bagi penyusun khususnya dan bagi semua yang membutuhkan umumnya. Akhir kata semoga Allah SWT rahmat, hidayah dan kasih sayangnnya kepada kita semua. Amiin ya rabbal alamin.

Wassalamu'alaikum Wr.Wb.

Yogyakarta, Juni 2021

penyusun
Mita Raehanun

DAFTAR ISI

KATA PENGANTAR.....	iv
DAFTAR ISI.....	vi
DAFTAR GAMBAR.....	viii
DAFTAR TABEL.....	ix
INTISARI.....	xiii
ABSTRACT	xiv
BAB I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah.....	3
1.3 Batasan Masalah	3
1.4 Tujuan Penelitian	4
1.5 Manfaat Penelitian	4
BAB II KAJIAN PUSTAKA	5
2.1. Kajian Pustaka	5
BAB III LANDASAN TEORI.....	9
3.1. Permintaan Emas Perhiasan	9
3.2. Analisis Deskriptif.....	9
3.2.1. Tabel	9
3.2.2. Grafik	10
3.3. Peramalan atau <i>Forecasting</i>	10
3.4. <i>Mean Absolute Percentage Error (MAPE)</i>	11
3.5. <i>Machine Learning</i>	12
3.6. Metode <i>Support Vector Machine</i>	12
3.7. Algoritma <i>Grid Search</i>	19
BAB IV METODOLOGI PENELITIAN.....	22
4.1 Populasi dan Sampel Penelitian	22
4.2 Jenis dan Sumber Data	22
4.3 Cara Pengambilan Data.....	22
4.4 Variabel dan Definisi Operasional Variabel.....	22
4.5 Metode Analisis Data	23
4.6 Proses Analisis Data	24

BAB V HASIL DAN PEMBAHASAN	26
5.1.1 Kategorisasi Data.....	27
5.1.2 <i>Prossesing Data</i>	29
5.1.3 <i>Analisis Time Series.....</i>	30
5.1.4 <i>Metode Supprt VektorMachin (SVM</i>	32
BAB VIIKESIMPULAN DAN SARAN	46
6.1. Kesimpulan.....	46
6.2. Saran	47
DAFATAR PUSTAKA	48

DAFTAR GAMBAR

Gambar 3. 1 Ilustrasi SVM.....	13
Gambar 4. 1 Flow Chart Analisis Data	24
Gambar 5. 1 Permintaan Emas di Negara-Negara Tertentu (Ton).....	26
Gambar 5.2Plot Time Series Negara Kategori Tinggi	31
Gambar 5. 3 Plot Time Series Kategori Rendah	32
Gambar 5. 4 Plot Svm Kategori Tinggi.....	33
Gambar 5. 5 Perbandingan Data Aktual dan Prediksi Negara India	36
Gambar 5. 6 Perbandingan Data Aktual dan Prediksi Negara Cina.....	37
Gambar 5. 7 Plot Model SVM Data Latih.....	40
Gambar 5. 8 Perbandingan Data Aktual dan Hasil Prediksi Negara Jepang.....	43
Gambar 5. 9 Perbandingan Data Aktual dan Hasil Prediksi Negara Vietnam	43

DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu.....	5
Tabel 3. 1 Tingkatan Nilai	11
Tabel 3. 2 Contoh Soal SVM	16
Tabel 3. 3 Contoh Perubahan Data Univariat ke Data Multivariat	18
Tabel 3. 4 Fungsi Kernel dalam SVM.....	19
Tabel 5. 1 Pengkategorian Permintaan Emas	28
Tabel 5. 2 Hasil Kategorisasi Dari 12 Negara	28
Tabel 5. 3 Negara Diramalkan.....	29
Tabel 5. 4 Pembagian Data Traininf dan Data Testing	30
Tabel 5. 5 Hasil Optimasi Parameter Negara India	33
Tabel 5. 6 Hasil Akurasi Nilai MAPE Negara India	34
Tabel 5. 7 Hasil Optimasi Parameter Negara Cina.....	35
Tabel 5. 8 Hasil Akurasi Nilai MAPE Negara Cina.....	35
Tabel 5. 9 Hasil Peramalan Permintaan Emas Empat Tahun Kedepan Negara India	37
Tabel 5. 10 Hasil Peramalan Permintaan Emas Empat Tahun Kedepan Negara Cina...	38
Tabel 5. 11 Hasil Optimasi Paramter Dari Masing-Masing Fungsi Kernel Jepang	40
Tabel 5. 12 Hasil Optimasi Paramter Dari Masing-Masing Fungsi Kernel Vietnam.....	41
Tabel 5. 13 Hasil Akurasi Dari Nilai MAPE Pada Setiap Fungsi Kenel Jepang	41
Tabel 5. 14 Hasil Akurasi Dari Nilai MAPE Pada Setiap Fungsi Kenel Jepang	42
Tabel 5. 15 Hasil Peramalan Permintaan Emas Empat Tahun Kedepan Negara Jepang	44
Tabel 5. 16 Hasil Peramalan Permintaan Emas Empat Tahun Kedepan Negara Vietnam	45

DAFTAR ISTILAH

SVM	: <i>Support Vector Machine</i>
ANN	: <i>Artificial Neural Networks</i>
MAPE	: <i>Mean Absolut Percentage Error</i>

DAFTAR LAMPIRAN

Lampiran 1 data permintaan emas perhiasan di 12 negara periode tahun 2000-2021

Lampiran 2 Script analisis aplikasi R.

PERNYATAAN

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang sebelumnya pernah diajukan untuk memperoleh gelar kesarjanaan di suatu perguruan tinggi dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan dalam daftar pustaka.

Yogyakarta, 17 Juni 2021



Mita Raehanun

INTISARI

**ANALISIS SUPPORT VECTOR MACHINE (SVM) DALAM PREDIKSI
PERMINTAAN EMAS PERHIASAN**

(Studi Kasus : Permintaan Emas Perhiasan dari Beberapa Negara Tertentu periode
Tahun 2010-2020)

Oleh : Mita Raehanun

Program Studi Statistika Fakultas MIPA
Universitas Islam Indonesia

Emas adalah salah satu investasi yang sangat menguntungkan karena emas menjanjikan keuntungan yang cukup besar. Emas tidak hanya berfungsi sebagai perhiasan seperti: kalung, cincin, gelang, dan anting, tapi fungsi lain dari emas adalah sebagai bahan baku industri teknologi dan kesehatan. Orang-orang percaya harga emas akan terus meningkat dari tahun ke tahun dan sifat emas yang likuid atau mudah dicairkan membuat orang-orang lebih memilih untuk berinvestasi emas dibandingkan dengan investasi lainnya yang likuiditasnya rendah, misalnya investasi properti. Permintaan emas dunia meningkat 6% per tahun pada kuartal ke-3 (Q3'19) menjadi 1,053.9 ton, data tersebut dirilis oleh World Gold Council. Itu setara dengan \$57,7 Miliar yang merupakan nilai tertinggi sepanjang waktu. Peningkatan ini didorong oleh permintaan investasi yang naik 33% per tahun menjadi 468,1 ton dan menghasilkan permintaan rekor kuartalan sebesar \$25,6 Miliar. Mengingat investasi emas yang menjanjikan keuntungan yang cukup besar, maka sangat perlu dilakukan studi yang mendalam, sehubungan dengan permintaan emas dari tahun ke tahun terus meningkat maka perlu dilakukan analisis tentang peramalan permintaan emas dari beberapa negara. Sebelumnya beberapa metode telah dikembangkan dalam peramalan harga emas. Salah satu metode yang dapat digunakan adalah metode kecerdasan buatan yang relatif baru dalam prediksi yaitu metode *Support Vector Machine* (SVM). Metode ini digunakan untuk melakukan prediksi baik dalam kasus klasifikasi maupun regresi. Dalam penelitian ini akan diramalkan jumlah permintaan emas perhiasan di beberapa negara yang akan dikelompokkan berdasarkan 2 kategori yaitu kategori tinggi dan rendah. Variasi fungsi kernel yang digunakan dalam SVM adalah RBF, Linear, dan, Polynomial. Hasil yang diperoleh dari uji coba penelitian ini menunjukkan bahwa model peramalan secara keseluruhan tergolong baik atau layak. Akurasi dari 2 model yang didapat dengan kernel RBF memiliki MAPE yang tergolong baik dan layak di kategori tinggi pada data *train*, sedangkan pada kategori tinggi juga tergolong baik.

Kata kunci: Peramalan, Permintaan Emas, SVM, MAPE, Fungsi Kernel.

ABSTRACT
SUPPORT VECTOR MACHINE (SVM) ANALYSIS IN PREDICTION
DEMAND FOR GOLD JEWELRY

(Case Study: Demand for Gold Jewelry from Certain Countries Period 2010-2020)

By: Mita Raehanun

*Statistics Study Program, Faculty of Mathematics and Natural Sciences
Indonesian Islamic University*

ABSTRACT

Gold is one of the most profitable investments because gold promises a large enough profit. Gold does not only function as jewelry such as necklaces, rings, bracelets, and earrings, but another function of gold is as a raw material for the technology and health industries. People believe that the price of gold will continue to increase from year to year and the liquid nature of gold makes people prefer to invest in gold compared to other investments with low liquidity, such as property investment. World gold demand increased 6% one year in the 3rd quarter (Q3'19) to 1,053.9 tonnes, the data released by the World Gold Council said. That equates to \$57.7 Billion which is an all-time high. This increase was driven by investment demand which rose 33% annually to 468.1 tonnes and generated a record quarterly demand of \$25.6 Billion. Given the gold investment that promises a large enough profit, it is very necessary to conduct an in-depth study, in connection with the demand for gold from year to year continues to increase, it is necessary to do an analysis of forecasting gold demand from several countries. Previously several methods have been developed in forecasting gold prices. One method that can be used is a relatively new artificial intelligence method in prediction, namely the Support Vector Machine (SVM) method. This method is used to make predictions both in the case of classification and regression. In this study, it will be predicted that the demand for gold jewelry in several countries will be grouped based on 2 categories, namely high and low categories. Variations of kernel functions used in SVM are RBF, Linear, and, Polynomial. The results obtained from the trial of this study indicate that the overall forecasting model is classified as good or feasible. The accuracy of the 2 models obtained with the RBF kernel has a MAPE that is classified as good and feasible in the high category on the data train, while in the high category it is also classified as good.

keywords: Forecasting, Gold Demand, SVM, MAPE, Kernel Function.

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Investasi yaitu penempatan sejumlah dana saat ini pada satu atau lebih aktiva yang dimiliki pada periode waktu tertentu untuk memperoleh keuntungan dimasa mendatang. Emas atau biasa disebut logam mulia juga merupakan salah satu instrumen investasi favorit karena nilainya yang selalu naik dari tahun ke tahun (Ikhsan,2019).

Penggunaan emas di zaman modern pada tahun 2017 emas memang sudah tidak digunakan lagi sebagai alat tukar perdagangan. Satu-satunya fungsi emas yang masih bertahan dari dulu sampai sekarang adalah kegunaannya sebagai perhiasan. Perhiasan merupakan sebuah benda yang digunakan untuk merias atau mempercantik diri. Perhiasan biasanya terbuat dari emas atau perak dan terdiri dari berbagai macam bentuk seperti kalung, cincin, gelang, liontin dan lain sebagainya. Diambil dari www.mrg.co.id. Di tahun 550 sebelum masehi, Raja Croesus dari Kerajaan Lydia (sekarang salah satu daerah di Turki), memerintahkan bawahannya untuk mencetak uang dalam bentuk koin emas. Uang ini kemudian dijadikan standar tukar untuk segala bentuk transaksi jual-beli di Kerajaan Lydia, hingga ke berbagai kerajaan tetangga yang ada pada waktu itu. Menjelang akhir abad 19, banyak negara yang menerapkan kebijakan “Standar Emas”, yakni mematok nilai mata uang mereka dengan emas dalam jumlah tertentu. Kebijakan ini bertahan cukup lama. Sejumlah negara seperti Amerika Serikat bahkan menggunakan standar emas ini hingga ratusan tahun lamanya. Beberapa negara seperti China dan India, konsumsi emas perhiasan masih sangat tinggi. Jumlah permintaan terhadap emas pun selalu naik dari India pada saat musim pernikahan terjadi.

Fungsi lain dari emas adalah sebagai bahan baku industri teknologi dan kesehatan. Selain itu, emas memiliki fungsi sebagai alat untuk berinvestasi. Banyak orang memilih untuk berinvestasi emas karena mereka percaya bahwa harga emas akan selalu mengalami kenaikan dari tahun ke tahunnya. Sifat investasi emas yang likuid atau mudah untuk dicairkan membuat orang-orang lebih memilih untuk berinvestasi emas

dibandingkan dengan investasi lainnya yang likuiditasnya rendah, seperti misalnya investasi properti.

Permintaan emas dunia meningkat 6% per tahun pada kuartal ke-3 (Q3'19) menjadi 1,053.9 Ton, data tersebut dirilis oleh World Gold Council. Itu setara dengan \$57,7 Miliar yang merupakan nilai tertinggi sepanjang waktu. Peningkatan ini didorong oleh permintaan investasi yang naik 33% per tahun menjadi 468,1 Ton dan menghasilkan permintaan rekor kuartalan sebesar \$25,6 Miliar. Menurut data tahun 2000 sampai dengan 2021 ada beberapa negara baru yang masuk dalam jajaran negara permintaan emas perhiasan seperti Sri Lanka, Kanada dan Spanyol. Mengingat investasi emas yang menjanjikan keuntungan yang cukup besar, maka sangat perlu dilakukan studi yang mendalam, sehubungan dengan permintaan emas dari tahun ke tahun terus meningkat maka perlu dilakukan analisis tentang peramalan permintaan emas dari beberapa negara, sebelumnya beberapa metode telah dikembangkan dalam peramalan harga emas. Salah satu metode yang dapat digunakan adalah metode kecerdasan buatan yang relatif baru dalam prediksi yaitu metode *Support Vector Machine* (SVM). Metode ini baik digunakan dalam kasus klasifikasi maupun regresi. Metode SVM adalah salah satu dari sekian banyak metode yang dapat digunakan untuk menyelesaikan berbagai jenis permasalahan termasuk peramalan. Dalam menyelesaikan sebuah permasalahan, SVM mampu menangani permasalahan nonlinier dengan adanya fungsi kernel yang membuat metode ini dapat digunakan untuk peramalan *time series*” (Naufal, 2017).

Penelitian dengan menggunakan metode SVM sudah banyak digunakan seperti pada penelitian yang dilakukan oleh (Dwi, 2015), Diperoleh hasil RMSE 4,620 pada variabel B mampu meningkatkan hasil prediksi (*open, high, low, close* dan *factory neus*) karena pada variabel A nilai RMSE nya sebesar 4,695. Penelitian berikutnya dilakukan oleh (Bode, 2018) pada penelitian ini selain menggunakan metode SVM penelitian ini juga menggunakan *Forward Selection* yang meneliti tentang penjualan obat dan menghasilkan model terbaik yang dilihat berdasarkan nilai error terkecil yaitu 0.135 dengan variabel periode 4, *validation Shuffled Sampling* 10 dan *type* kernel Polynomial. Kemudian pada eksperimen algoritma *Support Vector Machine* menggunakan fitur seleksi *Forward Selection* dihasilkan model terbaik yang dilihat berdasarkan nilai error

terkecil yaitu 0.133 dengan variabel periode 8, *Validation Shuffled Sampling* 10 dan type kernel Polynomial.

Support Vector Machine (SVM) merupakan salah satu algoritma *Machine learning* yang paling terkenal untuk klasifikasi dan regresi (Maali dkk, 2013). Konsep dasar SVM sebenarnya merupakan kombinasi harmonis dari teori-teori komputasi yang telah ada puluhan tahun sebelumnya, seperti *margin hyperplane* dan pernah ada upaya merangkaikan komponen-komponen tersebut (Vapnik, 1999). Dalam proses pembelajarannya, SVM memperkenalkan strategi baru dengan menemukan *hyperplane* yang terbaik pada *input space*, lewat strategi yang disebut *Structural Risk Minimization*. Keuntungan menggunakan metode SVM dibandingkan dengan metode peramalan yang lain salah satunya yaitu metode SVM digunakan untuk memprediksi nilai kesalahan lebih kecil dan lebih handal jika dibandingkan dengan metode jaringan syaraf tiruan (Ahmad dkk, 2014).

Berdasarkan latar belakang diatas, maka peneliti tertarik mengambil penelitian dengan tema yang berjudul “Analisis *Support Vector Machine* (SVM) Dalam Prediksi Permintaan Emas Perhiasan” peramalan metode SVM dirasa tepat untuk meramalkan permintaan emas di negara-negara tertentu.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, maka permasalahan yang dapat diidentifikasi dalam penelitian ini adalah:

1. Bagaimana penerapan metode SVM dalam meramalkan jumlah permintaan emas perhiasan di negara-negara tertentu dengan 2 kategori ?
2. Fungsi kernel manakah yang paling tepat dalam meramalkan jumlah permintaan emas perhiasan di negara-negara tertentu dengan 2 kategori ?
3. Bagaimana hasil ramalan jumlah permintaan emas di negara-negara tertentu dengan 2 kategori untuk beberapa periode kedepan ?

1.3 Batasan Masalah

Agar pembahasan dalam penelitian ini tidak terlalu luas, maka dalam penelitian ini diberikan batasan-batasan sebagai berikut:

1. Data yang digunakan adalah data total permintaan emas perhiasan 12 negara (ton) dari tahun 2000-2021 (India, Cina, Jepang, dan Vietnam)
2. Data diambil dari *Word Gold Council* www.gold.org
3. Aplikasi yang digunakan adalah *Microsoft Excel*, SPSS, dan R.

1.4 Tujuan Penelitian

Berdasarkan rumusan masalah maka tujuan yang ingin dicapai dalam penelitian ini adalah:

1. Menerapkan metode SVM untuk mendapatkan hasil peramalan jumlah permintaan emas di negara-negara tertentu dengan 2 kategori.
2. Mengetahui fungsi kernel yang tepat dalam meramalkan permintaan emas perhiasan dari beberapa negara tertentu dengan 2 kategori.
3. Mengetahui hasil analisa dari perolehan nilai peramalan jumlah permintaan emas perhiasan di negara-negara tertentu dengan 2 kategori.

1.5 Manfaat Penelitian

Adapun manfaat dari penelitian tugas akhir ini adalah:

1. Memberikan informasi kepada pihak perusahaan *word gold council* mengenai nilai peramalan jumlah permintaan emas perhiasan di negara-negara tertentu pada periode kedepan.
2. Pihak perusahaan bisa melakukan rencana mengambil keputusan terkait upaya peningkatan jumlah permintaan emas perhiasan di masing-masing negara untuk memperoleh keuntungan yang optimal.
3. Membantu perusahaan untuk membangun strategi dalam meningkatkan keuntungan seperti mengubah desain atau merancang bentuk- bentuk perhiasan yang bisa menarik konsumen agar lebih tertarik lagi untuk membeli perhiasan.

BAB II KAJIAN PUSTAKA

2.1. Kajian Pustaka

Untuk mencapai tujuan dalam menyelesaikan penelitian seperti yang dipaparkan pada bab sebelumnya, maka hal pertama yang dilakukan peneliti yaitu dengan dilakukannya kajian pustaka atau studi literatur dari penelitian atau jurnal penelitian terdahulu untuk membantu menyelesaikan penelitian yang akan diteliti oleh peneliti. Berikut beberapa jurnal yang digunakan sebagai dasar untuk menyelesaikan laporan penelitian ini:

Tabel 2. 1 Penelitian Terdahulu

No	Nama Peneliti	Judul	Metode	Hasil Penelilitian
1	(Mutmainnah ayu, 2018)	<i>Stock Price Forecasting Of PT Telekomunikasi Indonesia TBK.</i>	<i>Support Vector Machine (SVM)</i>	Model SVM terbaik dengan nilai parameter tertentu menggunakan metode <i>grid search</i> , diperoleh nilai <i>epsilon</i> , <i>cost</i> dan <i>gamma</i> . pada Variabel open model SVM $(\epsilon, cost, \gamma) = (0.2, 2048, 4)$ High SVM $(\epsilon, cost, \gamma) = (0.1, 4096, 8)$ Low SVM $(\epsilon, cost, \gamma) = (0.2, 64, 8)$ dan close SVM $(\epsilon, cost, \gamma) = (0.3, 88, 4)$.
2	Assaffat Lukman, 2015	Prakiraan Beban Listrik Harian Sektor Industri	<i>Support Vector Machine</i> dengan fungsi kernel	Pada prakiraan yang menggunakan metode SVM dengan fungsi Kernel Gaussian RBF, Rentang waktu pelatihan mempengaruhi <i>error</i> hasil prakiraan, semakin lama waktu

No	Nama Peneliti	Judul	Metode	Hasil Penelitian
			<i>Gaussian</i> RBF	pelatihan SVM maka nilai <i>error</i> prakiraan semakin kecil. Rentang waktu prakiraan ke depan pada prakiraan menggunakan metode SVM dengan fungsi Kernel Gaussian RBF mempengaruhi <i>error</i> hasil prakiraan, semakin lama waktu prakiraan ke depan maka nilai <i>error</i> prakiraan semakin besar
3	Colanus Ivo Rally Drajana, 2017	Pembayaran Bahan Baku Kopra	<i>Support Vector Machine</i> dan <i>Forward Selection</i>	Hasil eksperimen penelitian ini menunjukkan dimana <i>series</i> pembayaran algoritma SVM dan <i>Forward Selection</i> memberikan kinerja performa yang terbaik dibandingkan SVM. SVM dan <i>Backward Elimination</i> serta BPNN dan <i>Feature Selection</i> .
4	Bode Andi, 2018	Penjualan obat	<i>Support Vector Machine</i> dan <i>Forward Seelction</i>	Pada eksperimen algoritma Support Vector Machine dihasilkan model terbaik yang dilihat berdasarkan nilai error terkecil yaitu 0.135 dengan variabel periode 4, validation Shuffled Sampling 10 dan type kernel Polynomial. Kemudian pada eksperimen algoritma Support Vector Machine

No	Nama Peneliti	Judul	Metode	Hasil Penelitian
				menggunakan fitur seleksi Forward Selection dihasilkan model terbaik yang dilihat berdasarkan nilai error terkecil yaitu 0.133 dengan variabel periode 8, validation Shuffled Sampling 10 dan type kernel Polynomial.
5	Assaffat, Adi, dan Widodo, 2015	Prakiraan beban listrik harian pada sektor industri	<i>Support Vector Machine</i>	Proses peramalan SVM menggunakan fungsi kernel Gaussian RBF dengan waktu pelatihan 8 bulan diperoleh <i>error</i> dengan nilai MAPE sebesar 2,63 %.
6	Dwi Nugroho s, 2015	Prediksi harga emas	<i>Support Vector Machine</i>	Diperoleh hasil RMSE 4,620 pada variabel B mampu meningkatkan hasil prediksi (<i>open, high, low, close</i> dan <i>factory neus</i>) karena pada variabel A nilai RMSE nya sebesar 4,695.
7	Usep Tatang S, 2015	Prediksi Kelulusan Sertifikasi Benih Kentang	<i>Support Vector Machine</i> dan <i>Neural Network</i>	Hasil pengujian menunjukkan model dengan metode Neural Network memiliki akurasi sebesar 96.61% dan nilai AUC sebesar 0.997 sedangkan untuk metode Support Vector Machine memiliki nilai akurasi sebesar

No	Nama Peneliti	Judul	Metode	Hasil Penelitian
				98.91% dan nilai AUC sebesar 1.000. Sehingga dapat disimpulkan penerapan metode Support Vector Machine lebih baik dari Neural Network pada data sertifikasi benih kentang.
8	Naufal, M. F. (2017).	Peramalan Jumlah Wisatawan Mancanegara ang Datang ke Indonesia Berdasarkan Pintu Masuk	<i>Support Vector Machine (SVM).</i>	Pada penelitian ini didapatkan nilai MAPE sekitar 10% sehingga dapat disimpulkan model akurasi peramalan tergolong baik, dimana data yang dianalisis yaitu jumlah wisatawan mancanegara yang datang ke Indonesia dari 6 pintu masuk.

Dari beberapa penelitian yang dijadikan acuan peneliti untuk menyelesaikan penelitiannya dengan menggunakan metode SVM, sejauh ini peneliti tidak menemukan penelitian terdahulu mengenai peramalan permintaan emas di negara-negara tertentu di dunia menggunakan metode SVM ataupun menggunakan analisis metode peramalan lainnya.

BAB III

LANDASAN TEORI

3.1. Permintaan Emas Perhiasan

Permintaan merupakan jumlah dari suatu barang yang mau dan mampu dibeli pada berbagai kemungkinan harga selama jangka waktu tertentu dengan anggapan hal-hal lain tetap sama *ceteris paribus* (Gilarso, 2001). Harga adalah ukuran terhadap besar kecilnya nilai kepuasan seseorang terhadap produk yang dibelinya (Gitosudarmo, 2014:272). Sedangkan Emas merupakan logam mulia yang sering dijadikan sebagai alat tukar dalam perdagangan maupun sebagai standar keuangan berbagai negara (Joesoef, 2008).

Nilai emas yang hampir tidak pernah mengalami penyusutan membuat pelaku bisnis atau masyarakat sering memilih emas untuk berinvestasi. Oleh karena itu, transaksi jual beli emas atau permintaan emas pada umumnya banyak mendatangkan keuntungan bagi pelaku bisnis di berbagai negara.

3.2. Analisis Deskriptif

Menurut Walpole (1995) statistika deskriptif adalah metode-metode yang berkaitan dengan pengumpulan dan penyajian suatu data sehingga memberikan informasi yang berguna. Sugiyono (2004:169) menambahkan penjelasan atau proses penarikan kesimpulan data pada statistika deskriptif dengan cara mendeskripsikan atau menggambarkan data yang telah terkumpul. Menurut Walpole (1995) metode ini memiliki tujuan untuk menguraikan tentang sifat-sifat atau karakteristik dari suatu keadaan dan membuat deskripsi atau suatu gambaran yang sistematis dan akurat mengenai fakta-fakta dan sifat-sifat dari fenomena yang diselidiki. Contoh dari penyajian data dalam statistika deskriptif adalah tabel, diagram, dan grafik.

3.2.1. Tabel

Tabel adalah alat bantu visual yang berfungsi menjelaskan suatu fakta atau informasi secara singkat, jelas, serta lebih menarik daripada kata-kata. Penyajian informasi yang menggunakan tabel lebih mudah dibaca dan disimpulkan. Bentuk tabel yang sering digunakan adalah tabel distribusi frekuensi, tabel

distribusi frekuensi relatif dan tabel kontingensi untuk data kualitatif dengan banyak kategori dalam baris maupun kolom (Hasan, 2001).

3.2.2. Grafik

Penyajian data dalam bentuk grafik atau diagram bertujuan untuk memvisualisasikan data secara keseluruhan dengan menonjolkan karakteristik-karakteristik tertentu dari data tersebut, seperti kenaikan atau penurunan yang terjadi dalam kelompok data tersebut. Jenis grafik atau diagram yang sering digunakan diantaranya adalah histogram, diagram batang dan daun, diagram garis, diagram lingkaran serta diagram kotak (Hasan, 2001).

3.3. Peramalan atau *Forecasting*

Menurut Hakim (2006) peramalan atau *forecasting* merupakan proses untuk memperkirakan beberapa kebutuhan di masa datang yang meliputi kebutuhan dalam ukuran kuantitas, kualitas, waktu, dan lokasi yang dibutuhkan dalam rangka memenuhi permintaan barang dan jasa. Awat (1990) menambahkan perkiraan atau pengukuran dapat dilakukan secara kualitatif maupun kuantitatif. Perkiraan secara kualitatif biasanya menggunakan pendapat dari para ahli pada bidangnya, sedangkan perkiraan secara kuantitatif menggunakan metode statistik dan matematik yang selanjutnya metode ini banyak dipakai, salah satu diantaranya adalah metode deret berkala.

Sedangkan definisi peramalan menurut Heizer dan Render (2011) merupakan perkiraan kejadian di masa depan yang dilakukan dengan menggunakan data historis dan proses kalkulasi untuk memprediksikan sebuah proyeksi atas kejadian di masa datang. Cara lain yang dapat ditempuh adalah dengan intuisi subjektif atau dengan model matematis yang disusun oleh pihak manajemen. Dimana peramalan memegang peranan penting, antara lain: (Hartini, 2011:18):

1. Memberikan penjadwalan sumber-sumber yang ada
2. Peramalan pada tingkat permintaan untuk produk, material, tenaga kerja, financial atau jasa adalah input penting untuk penjadwalan.
3. Peramalan juga dibutuhkan untuk menentukan kebutuhan sumber-sumber di masa yang akan datang.
4. Menentukan sumber-sumber daya yang diinginkan.

5. Semua organisasi atau perusahaan harus menentukan sumber apa yang mereka inginkan untuk dimiliki pada jangka

3.4. *Mean Absolute Percentage Error (MAPE)*

Mean Absolute Percentage Error (MAPE) merupakan salah satu ukuran ketepatan yang dapat digunakan untuk melihat ketepatan metode peramalan. MAPE adalah metode yang bekerja dengan cara menjumlahkan rata-rata seluruh persentase kesalahan untuk suatu data set yang diperoleh tanpa menghiraukan tanda. Semakin kecil nilai MAPE yang diperoleh maka hasil peramalan semakin baik dan akurat (Naufal, 2017). MAPE dapat dirumuskan seperti pada persamaan 3.1:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{x_t - f_t}{x_t} \right|}{n} \times 100\% \quad (3.1)$$

Dimana :

n = jumlah sampel

x_t = Nilai Aktual Indeks pada periode ke-t

f_t = Nilai Prediksi Indeks pada periode ke-t

Hasil yang diperoleh MAPE menentukan tingkat akurasi dari suatu peramalan. Jika nilai MAPE yang didapatkan dalam suatu peramalan itu kurang dari 10% maka tingkat akurasi dari hasil peramalan tersebut bisa dikatakan sangat baik, untuk hasil MAPE 10-20% menunjukkan hasil peramalan baik, untuk hasil MAPE 20-50% maka hasil ramalan layak atau cukup, serta suatu hasil ramalan dikatakan tidak baik jika hasil MAPE lebih dari 50%, seperti yang dijelaskan Tabel 3.1.

Tabel 3. 1 Tingkatan Nilai

MAPE	Hasil Peramalan
< 10%	Sangat Baik
$10 \leq \text{MAPE} < 20\%$	Baik
$20 \leq \text{MAPE} < 50\%$	Layak/ Cukup
$\geq 50\%$	Buruk

3.5. *Machine Learning*

Machine learning merupakan serangkaian teknik yang dapat membantu dalam menangani dan memprediksi data yang sangat besar dengan cara mempresentasikan data-data tersebut dengan algoritma pembelajaran (Danukusumo, 2017). Menurut Muller dan Guido (2016) *Machine learning* merupakan bagian integral dari banyak aplikasi komersial dan proyek penelitian pada saat ini, di berbagai bidang mulai dari diagnosa dan perawatan medis sehingga memudahkan menemukan seseorang di jejaring sosial. Fungsi *Machine Learning* :

- a. Dapat membangun sistem sendiri untuk mengetahui bagaimana perasaan orang-orang di twitter atau membuat prediksi tentang pemanasan global.
- b. Aplikasi *Machine Learning* tidak terbatas dengan jumlah data yang tersedia saat ini.
- c. Metode pada *Machine Learning* akan membantu para ilmuwan data dan peneliti.


3.6. *Metode Support Vector Machine*

Metode *Support Vector Machine* (SVM) merupakan suatu teknik untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi, yang sangat populer belakangan ini (Santosa, 2007). Dalam hal klasifikasi metode SVM berada dalam satu kelas dengan metode ANN (*Artificial Neural Networks*) dalam hal fungsi dan kondisi permasalahan yang bisa diselesaikan. Keduanya masuk dalam kelas *supervised learning*.

Terbukti dalam banyak implementasinya, metode SVM memberikan hasil yang lebih baik dibanding metode ANN, terutama dalam hal solusi yang dicapai. Perbedaan yang sangat menonjol adalah ANN menemukan solusi berupa *local* optimal sedangkan SVM menemukan solusi yang global optimal. Tidak heran bila setiap menjalankan ANN solusi dari *training* selalu berbeda. Inilah yang menyebabkan ANN disebut *local* optimal karena solusi yang dicapai tidak selalu sama. SVM selalu memiliki hasil solusi yang sama untuk setiap *running*. Dalam teknik ini, peneliti berusaha untuk menemukan fungsi pemisah (*classifier*) yang optimal yang bisa memisahkan dua *set* data dari dua kelas yang berbeda. Teknik ini menarik orang dalam bidang data *mining* maupun

Machine Learning karena performasinya yang meyakinkan dalam memprediksi kelas suatu data baru (Budi, 2010).

Secara teoritik *Support Vector Machine* dikembangkan untuk menyelesaikan permasalahan klasifikasi pada dua kelas dengan mencari *hyperplane* terbaik. *Hyperplane* merupakan fungsi untuk memisahkan antara dua kelas pada *input space*, sehingga dari data yang tersebar dapat dilakukan klasifikasi dan analisis regresi. Vapnik menerangkan bahwa setiap permasalahan dapat dimodelkan dengan menggunakan SVM (Naufal, 2017). Ilustrasi SVM dapat dilihat pada **Gambar 3.1**.



Gambar 3.1 Ilustrasi SVM

Sumber: (*Support Vector Machine* teori dan aplikasinya dalam Bioinformatika, 2003)

Pada **Gambar 3.1** (a) menunjukkan alternatif garis pemisah (*discrimination boundaries*) dimana *pattern* yang tergabung pada class -1 disimbolkan dengan warna merah (kotak), sedangkan *pattern* pada class +1, disimbolkan dengan warna kuning (lingkaran). Sedangkan pada Gambar 3.1 (b) diperlihatkan bahwa terdapat garis *hyperplane* yang tepat berada diantara dua buah kelas. Prinsip dasar dari analisis ini adalah menemukan *hyperplane* terbaik yakni dengan meminimalkan kesalahan klasifikasi dan memaksimalkan margin geometrinya seperti pada Gambar 3.1 (b). Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada SVM. (Nugroho dkk, 2003)

Hyperplane pemisah terbaik antara kedua *class* dapat ditemukan dengan mengukur *margin hyperplane* tsb. dan mencari titik maksimalnya. *Margin* adalah jarak antara *hyperplane* tersebut dengan *pattern* terdekat dari masing-masing *class*. *Pattern* yang paling dekat ini disebut sebagai *support vector*. Garis solid pada gambar 1-b menunjukkan *hyperplane* yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua kelas, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam adalah *support vector*. Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada SVM. (Nugroho dkk, 2003)

Data yang tersedia dinotasikan dengan $x \in R^d$ sedangkan label masing-masing dinotasikan $y^i \in \{-1, +1\}$ untuk $i = 1, 2, 3, \dots, n$ yang mana n adalah banyaknya data. Diasumsikan kedua kelas dapat terpisah secara sempurna oleh *hyperplane* yang berdimensi d , yang didefinisikan:

$$w \cdot x + b = 0 \quad (3.3)$$

Pattern x_i yang termasuk kelas -1 (sampel negatif) dan dapat dirumuskan sebagai *pattern* yang memenuhi pertidaksamaan:

$$w \cdot x + b \leq -1 \quad (3.4)$$

Sedangkan *pattern* x_i yang termasuk kelas +1 (sampel positif)

$$w \cdot x + b \geq +1 \quad (3.5)$$

dengan:

w = vektor bobot

x = nilai masukan atribut

b = bias

Margin terbesar dapat ditemukan dengan memaksimalkan nilai jarak antara jarak dan titik terdekatnya, yaitu $1/\|w\|$. Hal ini dapat dirumuskan sebagai *Quadratic Programming (QP) problem*, yaitu mencari titik minimal persamaan 3.4, dengan memperlihatkan *constraint* persamaan 3.5.

$$\min_w = \tau(w) = \frac{1}{2} \|w\|^2 \quad (3.6)$$

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad (3.7)$$

Masalah ini dapat dipecahkan dengan berbagai teknik komputasi, diantaranya *lagrange multiplier* yang dinyatakan pada persamaan 3.6.

$$Lp = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i y_i (w \cdot x_i + b) - 1 \quad (3.8)$$

dengan $i = 1, 2, \dots, l$

Dimana a adalah *lagrange multiplier*, yang bernilai 0 atau positif $a_i \geq 0$. Untuk meminimalkan *lagrange*, maka persamaan 3.6 harus diturunkan terhadap w dan b dan diset dengan nilai 0 untuk syarat optimasi diatas:

Syarat 1:

$$\frac{\partial Lp}{\partial w} = 0 \rightarrow w = \sum_{i=1}^N \alpha_i y_i x_i \quad (3.9)$$

Syarat 2:

$$\frac{\partial Lp}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i y_i = 0 \quad (3.10)$$

N adalah jumlah data yang menjadi *support*

Karena *lagrange multiplier* (α) tidak diketahui nilainya, maka persamaan diatas tidak dapat menyelesaikan masalah tersebut. Untuk menyelesaikan masalah tersebut, modifikasi persamaan 3.4 menjadi kasus memaksimalkan L terhadap a_i , dengan memperhatikan sifat bahwa pada titik optimal gradient $L=0$ persamaan 3.4 dapat dimodifikasi sebagai maksimal L problem yang hanya mengandung a_i , sebagaimana terlihat pada persamaan 3.9 dan 3.10 dibawah ini.

$$\sum_{i=1}^l a_i - \frac{1}{2} \sum_{i,j=1}^N a_i a_j y_i a_j x_i \cdot x_j \quad (3.11)$$

$$a \geq 0 (i = 1, 2, \dots, l) \sum_{i=1}^N a_i y_i = 0 \quad (3.12)$$

$a_i \cdot a_j$ adalah lagrange multiplier yang berkorespondensi dengan $x_i \cdot x_j$

$x_i \cdot x_j$ merupakan *dot-product* dua data dalam data *training*

Dengan demikian, maka akan diperoleh a_i yang kebanyakan bernilai positif yang disebut sebagai *support vector* dan juga memperoleh persamaan 3.11 dan 3.12 yang merupakan nilai *weight* dan *bias* sebagai solusi pemisah.

$$w = \sum a_i y_i x_i \quad (3.13)$$

$$b = y_k - w^T x_k \quad (3.14)$$

Contoh:

Misalkan diperoleh nilai Max Ld dengan $\alpha_1 = \alpha_2 = \alpha_3 = \alpha_4 = 0.25$ sehingga nilai Ld = 0.25.

Tabel 3. 2Contoh Soal SVM

X_1	X_2	Kelas (Y)
1	1	-1
1	-1	1
-1	1	1
-1	-1	-1

Sumber: (Cholissodin,2015)

Diketahui nilai w dan b :

$$w = \sum_{i=1}^n \alpha_i y_i \phi(X_i) = \begin{pmatrix} 0 \\ -0.71 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$$

Pilih salah satu *Support Vector Machine* dari kelas '+1' dan '-1' untuk menghitung nilai b

$$b = -\frac{1}{2}(wx^+ + wx^+) = -\frac{1}{2}\left(\begin{pmatrix} 0 \\ -0.71 \\ 0 \\ 0 \\ 0 \end{pmatrix} \begin{pmatrix} 1 \\ -\sqrt{2} \\ 1 \\ \sqrt{2} \\ -\sqrt{2} \end{pmatrix} + \begin{pmatrix} 0 \\ -0.71 \\ 0 \\ 0 \\ 0 \end{pmatrix} \begin{pmatrix} 1 \\ \sqrt{2} \\ 1 \\ \sqrt{2} \\ 1 \end{pmatrix}\right)$$

$$b = -\frac{1}{2}\left((-0.71)(-\sqrt{2}) + (-0.71)(\sqrt{2})\right) = 0$$

Setelah nilai w dan b diketahui, maka model SVM siap digunakan untuk proses klasifikasi.

$$f(\phi(x)) = \text{sign}(w \cdot \phi(x) + b) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i \phi(x_i) \cdot \phi(x) + b\right)$$

Misalkan data *testing* $x_t = (1,5)$ maka $K(x_1, x_t) = (\phi_{x_1}) \cdot (\phi_{x_t})$

X_t=(1,5)	X ₁	$K(1,t) = (x_1 \cdot x_t + 1)^2 = (1 \cdot 1 + 5 \cdot 1 + 1)^2 = 7^2 = 49$	$(-0.125)(49)$
	X ₂	$K(2,t) = (x_2 \cdot x_t + 1)^2 = (1 \cdot 1 + 5 \cdot (-1) + 1)^2 = 3^2 = 9$	$(0.25)(9)$
	X ₃	$K(3,t) = (x_3 \cdot x_t + 1)^2 = (1 \cdot (-1) + 5 \cdot 1 + 1)^2 = 5^2 = 25$	$(0.125)(25)$
	X ₄	$K(4,t) = (x_4 \cdot x_t + 1)^2 = (1 \cdot (-1) + 5 \cdot (-1) + 1)^2 = (-5)^2 = 25$	$(-0.125)(25)$

$$f(\phi(x_t)) = \text{sign}(w \cdot \phi((1,5)) + b) = \text{sign}(-6.125 + 1.125 + 3.125 - 3.125 + 0) = \text{sign}(-5) \Rightarrow -1$$

Jadi data $x_t = (1,5)$ masuk ke kelas *negative*

Pengerjaan SVM untuk mencari model terbaik salah satunya dengan menggunakan algoritma *grid search* yang akan melatih banyak pasangan model dari *range* nilai yang telah ditentukan.

Adapun tahapan peramalan metode SVM untuk *time series* adalah sebagai berikut (Ismail, 2014):

1. *Pre-processing* data, data diubah dari bentuk univariat ke bentuk multivariat dimana data multivariat tersebut menjelaskan bahwa harga yang akan datang/target (Y_t) dipengaruhi oleh harga periode sebelumnya.

Contoh:

Tabel 3. 3Contoh Perubahan Data Univariat ke Data Multivariat

Data Univariat			Data Multivariat		
Periode	Harga (Rp)		Y_{t-2}	Y_{t-1}	Y_t
1 Maret 2018	4463	→	4463	4426	4383
2 Maret 2018	4426		4426	4383	4340
3 Maret 2018	4383		4383	4340	4300
4 Maret 2018	4340		4340	4300	4267
5 Maret 2018	4300		4300	4267	4243
6 Maret 2018	4267		4267	4243	4227
7 Maret 2018	4243		4243	4227	4218
8 Maret 2018	4227				
9 Maret 2018	4218				

1. Pemodelan dengan SVM data *time series* bertujuan untuk menentukan fungsi atau model yang tepat, dimana fungsi dari model tersebut dapat digunakan untuk memprediksi nilai-nilai yang akan datang dengan baik (Drajana, 2017). Pada tahap ini dimulai dengan *input data training* SVM. Selanjutnya mulai membuat model SVM dari data *training* dengan model *default*.
2. Penentuan nilai parameter seperti *epsilon*, *C (cost)* dan γ (*gamma*) dilakukan dengan implementasi algoritma *grid-search*. *Grid-search* akan melatih banyak pasangan model dari *range* nilai yang telah ditentukan. Setelah itu, peneliti mendapatkan tipe kernel dengan *output* nilai parameter terbaik dalam meramalkan.

3. Peramalan data adalah tahap evaluasi dari sebuah hasil peramalan yang memiliki nilai akurasi yang baik. Pada penelitian ini dalam menentukan model SVM yang baik digunakan nilai dari rata-rata MAPE terkecil.

Secara sederhana konsep SVM adalah sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah class pada input space. Banyak teknik data mining dan *Machine Learning* yang dikembangkan dengan asumsi kelinieran, sehingga algoritma yang dihasilkan terbatas untuk kasus-kasus yang linear, maka untuk mengatasinya kita bisa menggunakan metode kernel (Enri,2018). Fungsi kernel yang biasa digunakan dalam SVM sebagai berikut:

Tabel 3. 4Fungsi Kernel dalam SVM

Jenis kernel	Definisi
Linear K	$K = (x, y) = x \cdot y$
Polynomial	$K(x, y) = (x \cdot y + c)^d$
Gaussian RBF	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$
Sigmoid	$K(x, y) = \tan(\alpha(x, y) + c)$

3.7. Algoritma *Grid Search*

Terdapat beberapa algoritma untuk menentukan parameter optimal pada model SVM, salah satunya adalah menggunakan algoritma *grid search*. Algoritma ini membagi jangkauan parameter yang akan dioptimalkan ke dalam *grid* dan melintasi semua titik untuk mendapatkan parameter yang optimal. Dalam aplikasinya, algoritma *grid search* harus dipandu oleh beberapa metrik kinerja, biasanya diukur dengan *cross-validation* pada data *training*. Oleh karena itu disarankan untuk mencoba beberapa variasi pasangan parameter pada *hyperplane* SVM. Pasangan parameter yang menghasilkan akurasi terbaik yang didapatkan dari uji *cross-validation* merupakan parameter yang optimal. Parameter optimal tersebut yang selanjutnya digunakan untuk model SVM terbaik. Setelah itu, model SVM tersebut digunakan untuk memprediksi data *testing* untuk mendapatkan generalisasi tingkat akurasi model (Naufal, 2017). Tahapan yang dilakukan dalam mengoptimalkan parameter adalah:

1. Inisialisasi Parameter

Menentukan nilai parameter C , γ dan ϵ yang kemudian akan di dapat parameter yang optimal untuk mendapatkan hasil terbaik. Semakin besar parameter C semakin besar finalisasi *error* untuk memaksimalkan margin (Enri,2018). Nilai C digunakan untuk mengontrol *tradeoff* antara *margin* dan *error* klasifikasi. Nilai C relatif penting untuk memaksimumkan *margin* dan meminimumkan jumlah *slack*. Untuk parameter γ (*gamma*) dikarenakan semakin besar γ semakin bagus nilai prediksi pada training dan semakin buruk pada validasi (Enri, 2018), parameter *gamma* digunakan untuk mengontrol kecepatan proses *learning* dengan kecepatan tersebut ditunjukkan oleh jumlah iterasi yang dibutuhkan untuk mencapai konvergen. Untuk parameter *epsilon* (ϵ) yang semakin kecil dapat menghasilkan tingkat akurasi yang semakin meningkat, hal ini disebabkan karena nilai variabel *epsilon* (ϵ) yang semakin kecil dapat menghasilkan nilai α yang optimal sehingga dapat menentukan *support vector* yang tepat. *Support vector* yang tepat tersebut dapat menghasilkan *hyperplane* (garis pemisah) untuk memisahkan kedua kelas tersebut semakin optimal. Dari kombinas-kombinasi parameter akan di masukkan ke dalam algoritma SVM, lalu kombinasi yang akan memberikan nilai akurasi MAPE terbaik.

2. Pemilihan Kernel

Penentuan nilai parameter SVM terbaik dengan metode *grid search* menggunakan kernel. Pemilihan kernel berpengaruh terhadap tingkat akurasi serta *root mean squared error*. Berdasarkan penelitian, kernel yang sesuai untuk peramalan adalah kernel *Radial Basic Function* (RBF) (Assafat, 2017). Sehingga kernel yang dipakai pada penelitian ini adalah *Radial Basic Function* (RBF). Dari parameter-parameter yang didapat dari hasil optimasi parameter akan diuji dengan menggunakan algoritma dengan kernel RBF. RBF merupakan salah satu kernel yang digunakan untuk menentukan parameter terbaik. Rumus RBF dapat dituliskan:

$$k(x_i, x_j) = \exp \left\{ -\frac{\|x_i - x_n\|^2}{2\sigma^2} \right\} \quad (3.13)$$

dengan:

k = kernel

x_i = nilai input

x_n = jumlah nilai input

σ^2 = variansi

BAB IV

METODOLOGI PENELITIAN

4.1 Populasi dan Sampel Penelitian

Pada penelitian ini populasi yang digunakan yaitu jumlah permintaan emas di 12 negara (ton). Sampel penelitian yang digunakan adalah permintaan emas perhiasan di negara-negara tertentu (ton) di beberapa negara di dunia. Pada penelitian ini data yang digunakan didapatkan dari situs web resmi *Word Gold Council* terkait dengan permintaan emas perhiasan di negara-negara tertentu di dunia periode tahun 2000-2021 per triwulan.

4.2 Jenis dan Sumber Data

Pada penelitian ini jenis data yang digunakan adalah data sekunder dalam bentuk triwulan periode tahun 2000-2021. Data pada penelitian ini diambil dari situs web resmi *Word Gold Council*.

4.3 Cara Pengambilan Data

Pengumpulan data pada penelitian ini menggunakan dua metode yaitu:

a. Studi pustaka

Pengumpulan data dan teori pada penelitian ini berdasarkan data dan teori yang relevan terhadap penelitian yang akan diteliti dengan melakukan studi pustaka terhadap literatur seperti buku, jurnal, artikel, dan penelitian-penelitian terdahulu

b. Studi Dokumenter

Penelitian ini menggunakan jenis data sekunder yang diperoleh dari situs web resmi *Word Gold Council* terkait dengan jumlah permintaan emas perhiasan di negara-negara tertentu (ton) di seluruh dunia.

4.4 Variabel dan Definisi Operasional Variabel

Tabel 4.1 berisi tentang penjelasan dan definisi operasional variabel masing-masing variabel penelitian.


Tabel 4. 1 Definisi Operasional Variabel

Variabel	Definisi Operasional Variabel
Periode Waktu (X)	Periode waktu menunjukkan dalam triwulan jumlah permintaan emas perhiasan di negara-negara tertentu (ton).
Total Permintaan Emas Perhiasan Di Negara-Negara Tertentu (ton) (Y)	Jumlah permintaan emas perhiasan di negara-negara tertentu (ton) per triwulan dari periode tahun 2000-2021.

4.5 Metode Analisis Data

Penelitian ini menggunakan tiga *software* yaitu *Microsoft Excel*, *SPSS*, dan *software R* dalam menganalisis data pada penelitian ini. pada penelitian ini memuat analisis *deskriptif*, kategorisasi data, dan peramalan menggunakan metode SVM. Hasil dari output tersebut akan digunakan untuk mengetahui penerapan metode SVM dan model SVM terbaik, meliputi nilai operasional parameter dan fungsi kernel terbaik berdasarkan nilai akurasi, dalam meramalkan permintaan emas perhiasan di beberapa negara tertentu (ton) di dunia dan mengetahui peramalan jumlah permintaan emas perhiasan di beberapa negara tertentu untuk beberapa periode tahun kedepan.

4.6 Proses Analisis Data



Gambar 4. 1 Flow Chart Analisis Data

Langkah awal dari analisis ini bisa dilihat dari *flowchart* gambar 4.1 proses pertama yaitu pengumpulan data yang akan dianalisis. Penelitian ini menggunakan data

total permintaan emas perhiasan di negara-negara tertentu (ton) dengan menggunakan dua variabel yaitu metode dalam bulan (X) dan total permintaan emas perhiasan di negara-negara tertentu (ton) (Y). Kemudian data yang sudah ada di analisis menggunakan analisis *Deskriptif*. Setelah dilakukannya analisis deskriptif maka data permintaan emas di negara-negara tertentu dikategorikan menjadi tiga kategori. Setelah melakukan tahapan-tahapan analisis SVM untuk meramalkan permintaan emas beberapa periode kedepan. Tahapan-tahapannya yaitu:

Pra proses data adalah proses pemeriksaan data jika ada data yang *missing* maka akan dilakukan penanganan tetapi jika data tidak ada yang *missing* maka akan dilanjutkan ke pembagian data dengan persentase 70:30 meliputi data pelatihan (*training*) dan data pengujian (*testing*).


1. Pemodelan dengan SVM. Hal pertama yang dilakukan pada tahapan ini adalah menentukan tipe kernel dan nilai parameter, selanjutnya melakukan training SVM dan memprediksi data testing agar mendapatkan generalisasi tingkat akurasi model tapi sebelumnya dipilih model SVM terbaik untuk melakukan peramalan
2. Nilai parameter parameter *C (cost)*, *epsilon*, dan *gamma* ditentukan oleh fungsi *kernel*. Tahapan ini merupakan penentuan tipe kernel.
3. Implementasi algoritma *grid-search* digunakan untuk menentukan nilai parameter *C (cost)*, *epsilon*, dan *gamma*. Untuk mendapatkan tipe kernel terbaik dalam meramalkan maka algoritma *grid-search* akan melatih banyak pasangan model dari range nilai yang telah ditentukan. Pada penelitian ini digunakan nilai MAPE terkecil, nilai MAPE kecil akan memiliki hasil peramalan yang baik.

BAB V

HASIL DAN PEMBAHASAN

5.1 Analisis Deskriptif

Sebelum melakukan penelitian yang lebih lanjut maka hal pertama yang dilakukan adalah melakukan analisis deskriptif pada variabel-variabel yang digunakan. Manfaat dari analisis deskriptif sendiri yaitu untuk memberikan gambaran umum mengenai suatu data sehingga bisa berbentuk informasi yang mudah dimengerti. Analisis deskriptif pada penelitian ini digunakan untuk melihat gambaran umum mengenai data jumlah permintaan emas dari 12 negara.



Gambar 5. 1Permintaan Emas di Negara-Negara Tertentu (Ton)

Priode 2000-2021

Analisis deskriptif merupakan suatu metode yang digunakan untuk melihat secara keseluruhan gambaran umum suatu data sehingga bisa berbentuk informasi yang mudah di pahami. Analisis deskriptif pada penelitian ini digunakan untuk melihat gambaran umum secara keseluruhan mengenai karakteristik data permintaan emas perhiasan di negara-negara tertentu (ton) pada periode 2000-2021.

Pada grafik diatas, dapat dilihat bahwa negara dengan permintaan emas tertinggi adalah China dan India dengan rata-rata permintaan emas dua puluh tahun terakhir masing-masing sebesar 138.98 ton dan 116.85 ton. Dua negara ini memiliki rata-rata

permintaan emas paling tertinggi dengan perbandingan yang cukup jauh dari negara-negara lainnya.

Berdasarkan artikel yang dipublikasi oleh CNN Indonesia, harga emas dunia kembali merangkak naik pada perdagangan hari Senin (8/4/2019). Hal ini diakibatkan oleh permintaan konsumen China dan India yang meningkat. Optimis damai dagang Amerika Serikat (AS) dan China yang semakin tinggi membuat konsumen di China kembali memburu emas batangan. Permintaan emas India juga cukup tinggi, hal ini disebabkan perayaan Festival Akshaya Tritiya yang dirayakan setiap tahun di negara tersebut. Pada hari perayaan umat Hindu tersebut, pembelian emas dianggap akan membawa keberuntungan. Hal inilah yang memicu permintaan emas di India cukup tinggi.

Adapun negara dengan permintaan emas terendah adalah negara Jepang, Vietnam, dan Inggris dengan rata-rata permintaan emas masing-masing sebesar 7.33, 5.28 dan 9.94 ton.

5.1.1 Kategorisasi Data

Terdapat dua variabel dalam penelitian ini yaitu variabel periode waktu dalam triwulan dan variabel permintaan emas di 12 negara periode 2000 - 2021. Dikarenakan tidak terdapat patokan khusus (standar tertentu) yang harus digunakan untuk mengkategorikan permintaan emas, maka peneliti melakukan pengkategorian terhadap 12 negara tersebut menjadi 2 kategori yaitu negara dengan permintaan emas tinggi, dan rendah. Setelah melakukan pengkategorian maka akan dipilih empat negara sebagai sampel dalam analisis permintaan emas perhiasan. Pengkategorian tersebut dilakukan berdasarkan jumlah permintaan emas pada setiap negara.

Berikut adalah pengkategorian permintaan emas berdasarkan nilai kuartil di 4 negara periode 2000-2021.

Tabel 5. 1Pengkategorian Permintaan Emas

Jumlah Permintaan	Kategori
Total Permintaan $\leq$ Q1	Rendah
$Q2 \geq$ Total Permintaan $>$ Q1	Tinggi

Permintaan emas pada setiap negara dikategorisasikan menjadi dua kategori yaitu kategori tinggi dan kategori rendah. Setiap negara akan masuk kedalam salah satu dari dua kategori, dari 12 negara akan masuk kedalam salah satu kategori, pengkategorian didasarkan pada nilai Kuartil sesuai pada tabel 5.1. Adapun hasil pengkategorian adalah sebagai berikut:

Tabel 5. 2Hasil Kategorisasi Dari 12 Negara

No	Nama Negara	Kategorik
1	India	1
2	Cina	1
3	Mesir	1
4	Turki	1
5	Amerika Serikat	1
6	Saudi Arabia	2
7	Indonesia	2
8	Uni Emirat Arab	2
9	Jepang	2
10	Vietnam	2
11	Italy	2
12	Inggris	2

Pada tabel 5.2 menunjukkan hasil kategorisasi dari 12 negara. Negara dengan kategori rendah menunjukkan bahwa negara tersebut memiliki permintaan emas

yang sangat sedikit. Sedangkan kategori tinggi berarti permintaan emas di negara tersebut cukup tinggi.

Dapat dilihat bahwa negara yang masuk dalam kategori permintaan emas yang tinggi adalah China, India, Mesir, Turki dan Amerika Serikat. Sedang untuk kategori rendah yaitu negara Indonesia, Arab Saudi, Uni Emirat Arab, Jepang, Vietnam, Italy dan Inggris. Berdasarkan pada hasil kategorisasi, maka peneliti akan melakukan peramalan pada dua kategori berdasarkan jumlah permintaan di setiap kategori.

Pada kategorisasi maka peneliti akan memilih 4 negara, dimana pada kategori tinggi diambil dua negara dan pada kategori rendah diambil 2 negara. Pemilihan keempat negara berdasarkan jumlah permintaan emas dari tahun 200-2001 dan negara-negara yang dipilih dalam penelitian ini terlihat pada tabel 5.3 dibawah.

Tabel 5. 3 Negara Diramalkan

No	Negara	Kategori
1	India	Tinggi
2	Cina	Tinggi
3	Jepang	Rendah
4	Vietnam	Rendah

5.1.2 *Prossesing Data*

Preprocessing data dipersiapkan dengan melakukan *cleaning* data dengan tujuan agar menghilangkan data-data yang hilang (*missing value*) Tahap berikutnya adalah pembagian data *train* dan *test*. Data dibagi ke dalam dua bagian, yaitu dengan persentase data *train* 70 % dari total data dan data *test* 30% dari total data.

Selanjutnya akan membagi data dalam dua bagian dimana yaitu data *train* dan data *test*. Data *train* sendiri digunakan untuk meningkatkan kinerja dari SVM terhadap data *test* untuk memilih parameter dan fungsi kernel terbaik untuk model. Model SVM yang didapatkan dari data *train* yang nantinya akan diterapkan pada data *test*. Berikut ini merupakan pembagian data *train* dan data *test*

Tabel 5. 4 Pembagian Data Taraininf dan Data Testing


Permintaan Emas	Periode	Total Data	Data Train	Data Test
Kategori Tinggi	2000-2021	84	59	25
Kategori Rendah	2000-2021	84	59	25


Setelah didapatkan pembagian data untuk *training* dan *testing*, proses selanjutnya adalah dengan menganalisis *trend* dari data *time series*.

5.1.3 Analisis Time Series

- **Plot Time Series Permintaan Emas Negara Kategori Tinggi**

Gambar 5.2 merupakan plot permintaan emas di kategori tinggi yaitu plot permintaan emas negara India dan Cina.







Gambar 5.2 Plot Time Series Negara Kategori Tinggi

Gambar 5.2 menunjukkan grafik permintaan emas kategori tinggi di negara India dan Cina. Pada grafik dua negara terdapat dua sumbu X dan Y, dimana sumbu X menyatakan periode waktu dalam triwulan sedangkan sumbu Y menyatakan permintaan emas di negara- negara tertentu (ton). Dari grafik diatas dapat dilihat bahwa negara dengan kategori tinggi cenderung memiliki pola data yang *irregular/* acak.

- **Plot Time Series Permintaan Emas Negara Kategori Rendah**

Gambar 5.2 merupakan plot permintaan emas di kategori rendah yaitu plot permintaan emas negara Jepang dan vietnam.






Gambar 5. 3 Plot Time Series Kategori Rendah

Gambar 5.3 menunjukkan grafik permintaan emas kategori rendah di negara Jepang dan Vietnam. Pada grafik dua negara terdapat dua sumbu X dan Y, dimana sumbu X menyatakan periode waktu dalam triwulan sedangkan sumbu Y menyatakan permintaan emas di negara-negara tertentu (ton). Pada gambar diatas, grafik tersebut memperlihatkan bahwa negara-negara dengan kategori rendah cenderung memiliki pola yang horizontal dengan adanya fluktuasi naik dan turun yang konstan.

5.1.4 Metode *Support Vector Machine*(SVM)

- **Kategori Tinggi**

Gambar 5.4 merupakan plot dari model SVM dari data latih yang telah dimuat serta telah di ditentukan nilai setiap prediksi yang dibuat oleh model berdasarkan data tersebut.



Gambar 5. 4 Plot SVM Kategori Tinggi

Hasil nilai prediksi diatas (berwarna merah) ditentukan secara *default* oleh sistem dan belum diatur tipe kernel serta nilai parameternya. Untuk mendapatkan hasil terbaik maka peneliti melakukan *tuning* model atau pengoptimalan model. Berikut ini merupakan hasil *tuning* model pada kategori periode tinggi.

Tabel 5. 5 Hasil Optimasi Parameter Negara India

Parameter	Variabel Fungsi Kernel		
	RBF	polinomial	linier
<i>Epsilon</i>	0.79	0.65	0.29
<i>Cost</i>	512	8	512

Tabel 5.5 merupakan hasil optimasi parameter dari masing-masing fungsi kernel. Penentuan parameter yang akan digunakan dalam meramalkan jumlah permintaan emas pada negara-negara dengan kategori permintaan emas tinggi di negara India berdasarkan pada nilai MAPE terkecil yang dihasilkan dari masing-masing fungsi kernel. Nilai MAPE terkecil menunjukkan akurasi yang besar. Dibawah ini merupakan nilai MAPE masing-masing kernel.

Tabel 5. 6 Hasil Akurasi Nilai MAPE Negara India

Parameter	Variasi Fungsi Kernel		
	RBF	Linear	Polynomial
<i>Epsilon</i>	22.64%	23.29%	22.49%
<i>Cost</i>	24.47%	24.80%	24.37%

Tabel 5.6 merupakan hasil akurasi yang didapatkan dari nilai MAPE pada setiap fungsi kernel. Dapat dilihat pada tabel diatas, jika ditinjau dari data *train*, nilai MAPE terkecil adalah nilai MAPE dari kernel RBF sebesar 22.64%, kemudian nilai MAPE terkecil kedua ada pada kernel *polynomial* sebesar 22.49% yang tidak jauh dari nilai MAPE tersebut hasil peramalan data *train* pada kernel RBF dan *Polynomial* tergolong layak/cukup. Selanjutnya akan dilihat nilai MAPE berdasarkan data *test*. Pada data *test*, nilai MAPE terkecil ada pada kernel *polynomial* dengan nilai MAPE sebesar 24.37%. Nilai MAPE pada kernel tersebut berarti bahwa hasil peramalan data *test* layak/cukup. Berdasarkan pertimbangan nilai MAPE pada data *train* dan *test* untuk masing-masing kernel, fungsi kernel RBF terpilih sebagai model terbaik untuk meramalkan permintaan emas pada negara India kategori permintaan emas tinggi dengan parameter paling optimal yaitu nilai *epsilon* sebesar 0.79, *cost* sebesar 152 dan *gamma* yang ditentukan secara *default* yaitu sebesar 1.

Tabel 5. 7 Hasil Optimasi Parameter Negara Cina

Parameter	Variasi Fungsi Kernel		
	RBF	Polynomial	Linear
<i>Epsilon</i>	0	0.72	0.38.
<i>Cost</i>	4	512	64


Tabel 5.7 merupakan hasil optimasi parameter dari masing-masing fungsi kernel. Penentuan parameter yang akan digunakan dalam meramalkan jumlah permintaan emas pada negara-negara dengan kategori permintaan emas tinggi di negara Cina berdasarkan pada nilai MAPE terkecil yang dihasilkan dari masing-masing fungsi kernel. Nilai MAPE terkecil menunjukkan akurasi yang besar. Dibawah ini merupakan nilai MAPE masing-masing kernel.

Tabel 5. 8 Hasil Akurasi Nilai MAPE Negara Cina

Parameter	Variasi Fungsi Kernel		
	RBF	Linear	Polynomial
<i>Epsilon</i>	11.11%	38.19%	22.95%
<i>Cost</i>	39.72%	27.29%	17.72%


Tabel 5.8 merupakan hasil akurasi yang didapatkan dari nilai MAPE pada setiap fungsi kernel. Dapat dilihat pada tabel diatas, jika ditinjau dari data *train*, nilai MAPE terkecil adalah nilai MAPE dari kernel RBF sebesar 11.11% tergolong baik.,Selanjutnya akan dilihat nilai MAPE berdasarkan data *test*. Pada data *test*, nilai MAPE terkecil ada pada kernel polynomial dengan nilai MAPE sebesar 17.22%. Nilai MAPE pada kernel tersebut berarti bahwa hasil peramalan data *test* baik. Berdasarkan pertimbangan nilai MAPE pada data *train* dan *test* untuk masing-masing kernel, fungsi kernel RBF terpilih sebagai model terbaik untuk meramalkan permintaan emas pada negara India kategori permintaan emas tinggi dengan parameter paling optimal yaitu nilai *epsilon* sebesar 0, *cost* sebesar 4 dan gamma yang ditentukan secara *default* yaitu sebesar 1.

Setelah mendapatkan model terbaik dalam meramalkan permintaan emas di negara-negara dengan kategori tinggi, maka selanjutnya dilakukan *plotting* grafik antara data aktual dengan data prediksi dari data *testing*. Berikut ini merupakan hasil *plotting* grafik antara data aktual dengan data prediksi dari data *testing*. Plot di bawah ini merupakan peramalan untuk periode empat tahun kedepan berdasarkan triwulan.



Gambar 5. 5 Perbandingan Data Aktual dan Prediksi Negara India

Gambar 5.5 menunjukkan bahwa data *testing* cukup dalam mengikuti pola data atau tidak berbeda jauh dari pola data aktual. Gambar tersebut juga menunjukkan hasil peramalan untuk permintaan emas pada negara India untuk periode 2021-2025 mendatang. Jika dilihat dari *plot*, dapat diketahui bahwa permintaan emas pada triwulan kedua pada tahun 2021 mendatang akan mengalami kenaikan sampai sehingga tahun 2022 mendatang. Setelah mengalami kenaikan, permintaan emas diprediksi kembali turun pada tahun 2022 pada triwulan ke-2.



Gambar 5. 6 Perbandingan Data Aktual dan Prediksi Negara Cina

Gambar 5.6 menunjukkan bahwa data *testing* cukup dalam mengikuti pola data atau tidak berbeda jauh dari pola data aktual. Gambar tersebut juga menunjukkan hasil peramalan untuk permintaan emas pada negara Cina untuk periode 2021-2025 mendatang. Jika dilihat dari *plot*, dapat diketahui bahwa permintaan emas pada triwulan kedua pada tahun 2021 mendatang akan mengalami kenaikan sampai sehingga tahun 2022 mendatang. Setelah mengalami kenaikan, permintaan emas diprediksi kembali turun pada tahun 2022 pada triwulan ke-2.

Tabel 5. 9 Hasil Peramalan Permintaan Emas Empat Tahun Kedepan Negara India

Periode	Permintaan Emas (Ton)
Triwulan 2 - 2021	146.18
Triwulan 3- 2021	145.31
Triwulan 4 - 2021	148.51
Triwulan 1 - 2022	150.1
Triwulan 2 - 2022	147.36
Triwulan 3 - 2022	134.94
Triwulan 4 - 2022	115.65
Triwulan 1 - 2023	95.77

Triwulan 2 - 2023	83.48
Triwulan 3 - 2023	85.45
Triwulan 4 - 2023	103.95
Triwulan 1 - 2024	135.87
Triwulan 2 - 2024	173.72
Triwulan 3 - 2024	208.36
Triwulan 4 - 2024	231.8
Triwulan 1 - 2025	239.57

Berdasarkan hasil peramalan tersebut didapatkan permintaan emas untuk periode empat tahun kedepan untuk negara India yang masuk kategori tinggi yaitu akan mengalami penurunan yang cukup jauh selama periode tahun 2023 hingga triwulan ke-3 pada tahun 2023. Penurunan tersebut masing-masing sebesar 19.88 hingga 70.22 ton. Selanjutnya permintaan emas kembali naik berturut-turut pada triwulan ke-4 tahun 2023 di angka 103.95 ton hingga triwulan ke-1 pada tahun 2025 sebesar 239.57.

Tabel 5. 10 Hasil Peramalan Permintaan Emas Empat Tahun Kedepan Negara Cina


Periode	Permintaan Emas (Ton)
Triwulan 2 - 2021	180.86
Triwulan 3- 2021	180.69
Triwulan 4 - 2021	177.99
Triwulan 1 - 2022	172.66
Triwulan 2 - 2022	165.19
Triwulan 3 - 2022	156.61
Triwulan 4 - 2022	148.36
Triwulan 1 - 2023	141.92
Triwulan 2 - 2023	138.58
Triwulan 3 - 2023	139.04
Triwulan 4 - 2023	143.32
Triwulan 1 - 2024	150.73


Triwulan 2 - 2024	160.07
Triwulan 3 - 2024	169.91
Triwulan 4 - 2024	178.91
Triwulan 1 - 2025	186.07

Berdasarkan hasil peramalan tersebut didapatkan permintaan emas untuk periode empat tahun kedepan untuk negara Cina yang masuk kategori tinggi yaitu akan mengalami penurunan yang tidak cukup jauh selama periode triwulan ke-2 tahun 2022 hingga triwulan ke-4 pada tahun 2023. Permintaan emas kembali naik berturut-turut pada triwulan ke-1 tahun 2024 di angka 103.95 ton hingga triwulan ke-1 pada tahun 2025.

- **Kategori Rendah**

Gambar dibawah ini merupakan plot dari model SVM dari data latih yang telah dimuat serta telah di ditentukan nilai setiap prediksi yang dibuat oleh model berdasarkan data tersebut.





Gambar 5. 7 Plot Model SVM Data Latih

Hasil nilai prediksi gambar 5.7 ditentukan secara *default* oleh sistem dan belum diatur tipe kernel serta nilai parameternya. Untuk mendapatkan hasil terbaik maka peneliti melakukan *tuning* model atau pengoptimalan model. Berikut ini merupakan hasil *tuning* model pada kategori periode rendah.

Tabel 5. 11 Hasil Optimasi Parameter Dari Masing-Masing Fungsi Kernel Jepang

Parameter	Variasi Fungsi Kernel		
	RBF	Polynomial	Linear
<i>Epsilon</i>	0.36	0.64	0.32
<i>Cost</i>	512	512	32

Tabel 5.11 merupakan hasil optimasi parameter darimasing-masingfungsi kernel. Penentuan parameter yang akan digunakan dalam meramalkan jumlah permintaan emas pada negara Jepang dengan kategori permintaan emas rendah berdasarkan pada nilai MAPE terkecil yang dihasilkan dari masing-masing fungsi

kernel. Nilai MAPE terkecil menunjukkan akurasi yang besar. Dibawah ini merupakan nilai MAPE masing-masing kernel.

Tabel 5. 12 Hasil Optimasi Parameter Dari Masing-Masing Fungsi Kernel Vietnam

Parameter	Variasi Fungsi Kernel		
	RBF	Polynomial	Linear
<i>Epsilon</i>	0.07	0.04	0.2
<i>Cost</i>	64	512	16

Tabel 5.12 merupakan hasil optimasi parameter darimasing-masingfungsi kernel. Penentuan parameter yang akan digunakan dalam meramalkan jumlah permintaan emas pada negara Vietnam dengan kategori permintaan emas rendah berdasarkan pada nilai MAPE terkecil yang dihasilkan dari masing-masing fungsi kernel. Nilai MAPE terkecil menunjukkan akurasi yang besar. Dibawah ini merupakan nilai MAPE masing-masing kernel.

Tabel 5. 13 Hasil Akurasi Dari Nilai MAPE Pada Setiap Fungsi Kenel Jepang

Data Set	Fungsi Kernel		
	RBF	Polynomial	Linear
<i>Data training</i>	19.27%	31.02%	23.87%
<i>Data test</i>	17.48%	168.27%	61.36%

Tabel 5.13 merupakan hasil akurasi yang didapatkan dari nilai MAPE pada setiap fungsi kernel. Dapat dilihat pada tabel diatas, jika ditinjau dari data *train*, nilai MAPE terkecil adalah nilai MAPE dari kernel RBF sebesar 19.27%, dari nilai MAPE tersebut hasil peramalan pada data *train* tergolong baik. Selanjutnya akan dilihat nilai MAPE berdasarkan data *test*. Pada data *test*, nilai MAPE terkecil ada pada kernel kernel RBF dengannilai MAPE sebesar 17.48% berarti bahwa hasil peramalan pada data *test* juga tergolong baik. Berdasarkan pertimbangan dari data *train* dan *test*, peneliti memilih fungsi kernel RBF sebagai model terbaik untuk meramalkan permintaan emas pada negara-negara kategori permintaan emas rendah


dengan parameter paling optimal yaitu nilai *epsilon* sebesar 0.36, *cost* sebesar 512 dengan tingkat permormanya sebesar 1.

Tabel 5. 14 Hasil Akurasi Dari Nilai MAPE Pada Setiap Fungsi Kenel Jepang

Data Set	Fungsi Kernel		
	RBF	Polynomial	Linear
Data training	25.67%	44.12%	39.36%
Data test	16.89%	20.64%	26.92%


Tabel 5.14 merupakan hasil akurasi yang didapatkan dari nilai MAPE pada setiap fungsi kernel. Dapat dilihat pada tabel diatas, jika ditinjau dari data *train*, nilai MAPE terkecil adalah nilai MAPE dari kernel RBF sebesar 25.67%, dari nilai MAPE tersebut hasil peramalan pada data *train* tergolong layak atau cukup. Selanjutnya akan dilihat nilai MAPE berdasarkan data *test*. Pada data *test*, nilai MAPE terkecil ada pada kernel kernel RBF dengannilai MAPE sebesar 16.89 % berarti bahwa hasil peramalan pada data *test* tergolong baik. Berdasarkan pertimbangan dari data *train* dan *test*, peneliti memilih fungsi kernel RBF sebagai model terbaik untuk meramalkan permintaan emas pada negara-negara kategori permintaan emas rendah dengan parameter paling optimal yaitu nilai *epsilon* sebesar 0.36, *cost* sebesar 512 dengan tingkat permormanya sebesar 1.

Setelah mendapatkan model terbaik dalam meramalkan permintaan emas di negara Jepang dengan kategori rendah, maka selanjutnya dilakukan *plotting* grafik antara data aktual dengan data prediksi dari data *testing*. Berikut ini merupakan hasil *plotting* grafik antara data aktual dengan data prediksi dari data *testing*. *Plot* dibawah ini merupakan peramalan untuk periode empat tahun kedepan berdasarkan triwulan.



Gambar 5. 8 Perbandingan Data Aktual dan Hasil Prediksi Negara Jepang

Gambar 5.8 menunjukkan bahwa data *testing* cukup dalam mengikuti pola data atau tidak berbeda jauh dari pola data aktual. Gambar tersebut juga menunjukkan hasil peramalan untuk setiap triwulan pada periode tahun 2021-2025. Jika dilihat dari *plot*, dapat diketahui bahwa permintaan emas pada negara Jepang pada periode 2021 hingga 2025 mendatang akan mengalami penurunan. Berikut ini merupakan hasil ramalan dari model terbaik.



Gambar 5. 9 Perbandingan Data Aktual dan Hasil Prediksi Negar Vietnam

Gambar 5. menunjukkan bahwa data *testing* cukup dalam mengikuti pola data atau tidak berbeda jauh dari pola data aktual. Gambar tersebut juga menunjukkan hasil peramalan untuk setiap triwulan pada periode tahun 2021-2025. Jika dilihat dari *plot*, dapat diketahui bahwa permintaan emas di negara Vietnam pada periode 2021 hingga 2022 permintaanya konstan menurun pada triwulan ke-3 tahun 2022 dan kembali meningkat di tahun 2024 triwulan ke-2.

Tabel 5. 15 Hasil Peramalan Permintaan Emas Empat Tahun Kedepan Negara Jepang

Periode	Permintaan Emas (Ton)
Triwulan 2 - 2021	4.17
Triwulan 3- 2021	4.27
Triwulan 4 - 2021	4.31
Triwulan 1 - 2022	4.29
Triwulan 2 - 2022	4.15
Triwulan 3 - 2022	3.93
Triwulan 4 - 2022	3.69
Triwulan 1 - 2023	3.49
Triwulan 2 - 2023	3.38
Triwulan 3 - 2023	3.33
Triwulan 4 - 2023	3.26
Triwulan 1 - 2024	3.07
Triwulan 2 - 2024	2.68
Triwulan 3 - 2024	2.05
Triwulan 4 - 2024	1.22
Triwulan 1 - 2025	0.29

Berdasarkan tabel 5.15 peramalan hasil peramalan pada negara Jepang didapatkan permintaan emas untuk periode 2021 sampai tahun 2022 triwulan ke- 2 permintaan masih konstan di angka 4.15 ton dan permintaan menurun sekitar 0.22 ton pada tahun 2022 triwulan ke-3 terus mengalami penurunan sampai tahun 2025 triwulan ke-1 dimana permintaanya sebesar 0.29 ton.

Tabel 5. 16 Hasil Peramalan Permintaan Emas Empat Tahun Kedepan Negara Vietnam

Periode	Permintaan Emas (Ton)
Triwulan 2 - 2021	4.46
Triwulan 3- 2021	4.62
Triwulan 4 - 2021	4.72
Triwulan 1 - 2022	4.68
Triwulan 2 - 2022	4.44
Triwulan 3 - 2022	4.00
Triwulan 4 - 2022	3.43
Triwulan 1 - 2023	2.87
Triwulan 2 - 2023	2.49
Triwulan 3 - 2023	2.46
Triwulan 4 - 2023	2.86
Triwulan 1 - 2024	3.72
Triwulan 2 - 2024	4.92
Triwulan 3 - 2024	6.3
Triwulan 4 - 2024	7.64
Triwulan 1 - 2025	8.75

Berdasarkan tabel 5.16 peramalan hasil peramalan pada negara Vietnam didapatkan permintaan emas untuk periode 2021 sampai tahun 2022 triwulan ke- 2 permintaan masih kostan di angka 4.44 ton dan permintaan menurun sekitar 0.44 ton pada tahun 2022 triwulan ke-3 di tahun 2024 triwulan ke-2 permintaan kembali meningkat di angka 4.92.

BAB VII

KESIMPULAN DAN SARAN

6.1. Kesimpulan

Berdasarkan hasil analisis pada bab sebelumnya dapat diambil kesimpulan sebagai berikut:

1. Berdasarkan hasil pengujian 2 kategori pada beberapa negara, metode SVM dapat digunakan sebagai pilihan dalam meramalkan jumlah permintaan emas perhiasan karena didapatkan rata-rata nilai MAPE tergolong baik dan layak/cukup.
2. Berdasarkan hasil pengujian dari ke 2 kategori, fungsi kernel yang paling tepat digunakan dalam meramalkan jumlah permintaan emas perhiasan adalah fungsi kernel RBF karena nilai akurasi yang didapatkan pada pengujian tersebut tergolong baik.
3. Hasil peramalan empat tahun kedepan di negara kategori tinggi yaitu negara India dan Cina. Permintaan perhiasan di negara india mengalami penurunan yang cukup jauh selama periode tahun 2023 hingga triwulan ke-3 pada tahun 2023. Sedangkan untuk negara Cina permintaan akan mengalami penurunan yang tidak cukup jauh selama periode triwulan ke-2 tahun 2022 hingga triwulan ke-4 pada tahun 2023. Permintaan emas kembali naik berturut-turut pada triwulan ke-1 tahun 2024 triwulan ke-1 pada tahun 2025. Hasil peramalan empat tahun kedepan di negara kategori rendah yaitu negara Jepang dan Vietnam. Permintaan emas di negara Jepang untuk periode 2021 sampai tahun 2022 triwulan ke- 2 permintaan masih kosten, permintaan menurun pada tahun 2022 triwulan ke-3 sampai tahun 2025 triwulan ke-1. peramalan hasil peramalan pada negara Vietnam didapatkan permintaan emas untuk periode 2021 sampai tahun 2022 triwulan ke- 2 permintaan masih kosten di angka 4.44 ton dan permintaan menurun sekitar 0.44 ton pada tahun 2022 triwulan ke-3 di tahun 2024 triwulan ke-2 permintaan kembali meningkat di angka 4.92.

6.2. Saran

Saran untuk penelitian berikutnya. Penelitian ini menggunakan metode SVM untuk meramalkan jumlah permintaan emas perhiasan di negara-negara tertentu yang di kategorikan menjadi 2 kategori, diharapkan pada penelitian selanjutnya dilakukan dengan metode lain dan melakukan pengujian untuk negara yang berbeda. Hal tersebut digunakan untuk membandingkan akurasi peramalan dari setiap untuk melihat metode mana yang paling cocok digunakan dalam meramalkan permintaan emas perhiasan di negara-negara tertentu.

Dilihat dari hasil peramalan untuk negara kategori rendah yaitu negara Jepang dan Vietnam jumlah permintaannya tidak stabil bahkan cenderung menurun, maka sebaiknya untuk perusahaan meningkatkan penjualan dengan membuat perhiasan yang desainnya bisa menarik orang-orang untuk lebih tertarik membeli perhiasan supaya perusahaan mendapatkan keuntungan yang optimal.

DAFATAR PUSTAKA

- Ahmad, dkk. 2014, *A Review on Applications of ANN And SVM For Building Electrical Energy Consumption Forecasting, Renewable And Sustainable Energy Reviews* 33, 102–109
- Assaffat, L., 2015. *Analisis Akurasi Aplication Of Support Vektor Machine Dengan Fungsi Kernel Gaussian Rbf Untuk Prakiraan Beban Listrik Harian Srektor e* . Vol. 11, no.2, Okt 2015 hal. 64-68 ISSN 0216-7395, e-ISSN 2406-9329.
- Assaffat, L., Kusworo H., & Ahmad W., 2015. *Aplication Of Support Vektor Machine Untuk Prakiraan Beban Listrik Hatian Pada Sektor Industri*. Vol. 24, September 2015, ISSN 1693-8738.
- Awat, J. N. 1990. *MetodePeramalanKantitatif*. Yogyakarta: Liberty.
- Bode, A., 2018. *Aplication Of Support Vektor MachineMenggunakan Forward Selection Untuk Prediksi Penjualan Obat*. vol 3 no.1 Oktober 2018.
- Bodie,dkk, (2010). *Pengertian investasi*. Yogyakarta
- Colanus, I. R. D., 2017. *Metode Aplication Of Support Vektor Machine Dan Forward Selection Prediksi Pembayaran Bahan Baku Kopra*. Vol. 9, no 2 Agustus 2017 ISSN cetak 2087-1716 ISSN online 25487779.
- Danukusumo, K. P. 2017. *Implementasi Deep Learning Menggunakan Convolutional Neural Network UntukKlasifikasi Citra Candi Berbasis GPU*. Yogyakarta: UniversitasAtma Jaya.
- Dwi, N. 2015. *Penerapan Algoritma Aplication Of Support Vektor Machine Untuk Prediksi Harga Emas*. Vol .1, edisi Juni 2015.
- Enri, U. 2018. *Optimasi Parameter Support Vector Machines untukPrediksi Nilai Tukar Rupiah Terhadap Dollar Amerika Serikat*. JurnalGerbang, Vol 8, no. 1

- Gilarso. 2001. *Pengantar Ilmu Ekonomi*. Yogyakarta: Kanisius
- Hakim, A. N. 2006. *Manajemen Industri*. Yogyakarta: Andi Offset.
- Hartini, S. 2011. *Teknik Mencapai Produksi Optimal*. Bandung: Lubuk Agung
- Hasan, I. 2001. *Pokok-Pokok Materi Statistik 2 (Statistik Inferentif)*. Edisi kedua. Jakarta: PT Bumi Aksara
- Heizer, J., & Render, B. 2011. *Operations Management*. Edisi Kesembilan Buku Dua. Jakarta: Salemba Empat
- Ihksan, K. 2019. *Analisis Keuntungan Investasi Emas Dengan IHSG* Vol. 3. No.2 (16-23)
- Ismail, M. (2014). *Algoritma Support vector Machine untuk Memprediksi Rentet Waktu Harga Daging Ayam Broiler dan Telur Ayam Broiler*. Semarang: Universitas Dian Nuswantoro.
- Gitosudarmo, I. 2014. *Manajemen Pemasaran*. Yogyakarta: IKAPI
- Joesoef, J. R. 2008. *Pasar Uang dan Pasar Valuta Asing*. Jakarta: Salemba Empat
- Maali, Y., Al-Jumaily, A., 2013, *Self-Advising Support Vector Machine, Knowledge-Based Systems* 52, 214–222.
- Muller. A. C., & Guido. S. 2016. *Introduction to Machine Learning with Python.: a guide for data setists*. O'Reilly Media
- Mutmainnah, A., 2018. *Aplication Of Support Vektor Machine (SVM) Methods On Stock Price Forecasting Of PT Telekomunikasi Indonesia TBK*. ISBN: 978-602-5614-35-4.
- Naufal, M. F. (2017). *Peramalan Jumlah Wisatawan Mancanegara yang Datang ke Indonesia Berdasarkan Pintu Masuk Menggunakan Metode Support Vector Machine (SVM)*.

- Nugroho, S.A., Witarto, B.A., dan Handoko, D. (2003). Teori dan Aplikasinya dalam Bioinformatika. *Support Vector Machine*, <http://ilmukomputer.com>.
- Santosa, B., &Widyarini, T. 2009. *AplikasiMetode Cross Entropy Untuk Support Vector Machines*. Vol.10, no. 2 (107-115)
- Santosa, B. 2007. *Data Mining Teknik Pemanfaatan Data untukKeperluanBisnis*.Yogyakarta: GrahaIlmu
- Santosa, P. B., &Ashari. 2005. *AnalisisStatistikdengan Microsoft Excel dan SPSS*. Yogyakarta: Andi
- Sugiyono. 2014. *Metode Penelitian*. Bandung: Alfabeta.
- Supranto. 2009. *Statistik 2, Edisikeenam*. Jakarta: Erlangga
- Usep tatang, S. 2015. *Komparasi Support Vector Machine Dan Neural Network Untuk Prediksi Kelulusan Sertifikasi Benih Kentang*. ISSN:19792328
- Vapnik, V.N., 1999.*The Nature of Statistical Learning Theory 2nd edition*, Springer-Verlag, New York Berlin Heidelberg
- Walpole, R. E. 1995.*PengantarStatistika, edisi ke-3*. Jakarta: PT Gramedia Pustaka Utama
- Yasin, H. A., Prahutama., &Utami, T. 2014.*Prediksi Harga Saham Menggunakan Support Vector Regression denganAlgoritma Grid Search*. Media Statistika, Vol. 7, no. 1 (29-35)

LAMPIRAN

no	NAMA NEGARA	Q2'00	Q3'00	Q4'00	Q1' 01	Q2' 02	Q3' 03	Q4' 04	Q1' 02	Q2' 02	Q3'02	Q4'02
1	india	148.9	134.9	182.6	194.7	180.3	107.6	132.2	104.1	119.2	103.9	163
2	china	45.9	45.9	58.9	55	45.8	48	54.3	55.6	44	45	54
3	japan	11.9	15.2	14.1	10.8	12.5	14.8	12.5	12.2	11.7	11.7	10.9
4	indonesia	19	19.5	24.4	25	18	28.5	26.3	23.5	22.8	25.2	21.3
5	vietnam	3.9	4.8	5.3	7.1	4	5.9	6.8	7	4.8	5.9	7
6	saudi arabia	42.6	38	38.8	47.4	43.3	35.9	36.8	40.4	34.5	30	34.4
7	egypt	31.8	34.8	28.7	29.7	28.8	31.5	25.9	19.3	18.5	23.7	20.5
8	UAE	24.2	17.4	24.9	30.5	25.8	16.4	22.2	27	23.2	16.3	21.8
9	turkey	35.7	49.2	27.1	23.9	10.8	32.3	25.4	17.9	20.7	34.7	24.5
10	USA	64.2	91.2	157.6	78	65.4	84.9	161.1	80.2	66.1	87.7	154.1
11	italy	18.4	13.8	45.1	14.7	18.3	13.7	44.9	14.3	17.3	13.1	42.9
12	UK	10.4	12.4	41.1	11.3	11.4	13.1	46	11.4	10.9	12.2	43.1

no	NAMA	Q1' 03	Q2' 03	Q3'03	Q4'03	Q1' 04	Q2'04	Q3'04	Q4'04	Q1'	Q2'0	Q3'05	Q4'0
----	------	--------	--------	-------	-------	--------	-------	-------	-------	-----	------	-------	------

	NEGARA									05	5		5
1	india	115	197.3	131	121.7	118.5	171.5	126.5	147	179.8	227	115	67.4
2	china	57.6	39.4	51.9	58.7	59	50	53	62.2	66.8	55.4	57.7	63.4
3	japan	24.1	19.7	18.8	30.2	11.8	11.8	11.3	11.4	8.8	8.3	8.3	8.6
4	indonesia	14.6	13	24.5	20.9	20.7	21.4	26.7	18.1	18.9	21.6	22.6	16.4
5	vietnam	12.2	38.7	14.5	19	7.6	5.1	5.7	8	8.5	5.6	5.8	7
6	saudi arabia	35	14.7	30.4	29	37.1	41.7	32.9	28.7	35.4	48	37.4	29.5
7	egypt	17.6	25.7	18.2	16.2	19.8	15.9	19.7	17.6	21.1	17.1	20.7	16.3
8	UAE	23.8	14.7	19	19.3	26.9	26.4	18.4	17.6	29.8	28.9	20.8	16.5
9	turkey	47.7	49.7	80.2	30.8	42.6	48.8	67.7	30.5	54.7	48.9	64.5	30.6
10	USA	70.7	59	78	167	63.9	61.2	77.8	155.8	62.6	61.6	77.8	152.2
11	italy	21	15.7	11.9	41.4	12.4	15	11.3	38.9	11.8	13.9	10.5	36.6
12	UK	3.1	9.6	13	39.3	10.5	9.1	13	37.6	8.9	7.8	10.2	30.8

no	NAMA NEGARA	Q1' 06	Q2'06	Q3'06	Q4'06	Q1' 07	Q2'07	Q3'07	Q4'07	Q1' 08	Q2'08	Q3'08	Q4'08
----	----------------	--------	-------	-------	-------	--------	-------	-------	-------	-----------	-------	-------	-------

1	india	103.1	135	127.8	151	147	240	134.8	54	71.1	118	178.5	102.1
2	china	64.3	54.5	60.4	65.5	81.6	70.6	74.8	77.3	86.6	68.7	86.3	85.1
3	japan	8.5	8.4	7.8	8.7	8.2	7.9	8	8	7.4	7.3	7	6.5
4	indonesia	16.2	15.1	16.6	13.7	15.6	13.7	16.1	12.7	11.3	10.3	20	9.9
5	vietnam	5.6	5.6	6.2	6.4	6.5	6	5.1	5.5	5.3	4.7	5	4.8
6	saudi arabia	26.7	32.4	31.6	28.6	24.3	39.6	31.7	22.4	19.5	33.7	37.8	17.8
7	egypt	13.4	11.9	17.8	16	15.5	13.1	21.3	17.4	16.6	14.1	22.1	18.7
8	UAE	26	23.4	20.8	17.8	27.8	27.8	24.3	17.4	21.9	24.4	30	17.1
9	turkey	30.9	45.8	54.8	32	32.8	52.2	66.6	19.3	28.9	42.5	67.2	16.5
10	USA	59.5	54.2	71.2	126.4	54.2	51	60	104.6	39.5	33	41.1	65.5
11	italy	9.9	13.9	9	31.1	9.3	12.6	8.3	28.6	8	10.6	6.9	24.4
12	UK	7.7	7.1	8.9	26.7	7.8	8.2	8.7	24.7	5.7	6.9	6.1	17.7

no	NAMA NEGARA	Q1' 09	Q2'09	Q3'09	Q4'09	Q1'10	Q2'10	Q3'10	Q4'10	Q1'11	Q2'11	Q3'1 1	Q4'1 1
1	india	34.7	88	111.6	137.8	190.9	117.3	166.6	186.9	198.8	179.8	127.0	113.7

2	china	89.1	72.5	93.5	86.5	121.0	91.1	118.8	131.1	154.3	114.6	140.4	147.9
3	japan	6.7	5.2	5.9	6.2	4.8	4.8	4.2	7.0	4.0	3.9	4.1	3.9
4	indonesia	10.8	10.3	13.6	9	9.6	6.3	11.0	6.5	10.8	6.1	9.6	6.9
5	vietnam	4.6	3.9	4	3.7	5.1	3.1	2.9	3.1	5.4	2.9	2.0	2.4
6	saudi arabia	15	28	25.3	14.1	17.0	25.4	17.7	9.9	13.5	19.6	12.9	8.7
7	egypt	14.9	13	16.6	12.2	20.6	17.6	15.6	13.2	21.3	16.5	9.8	8.7
8	UAE	14.6	19.7	19.8	14.7	17.7	8.9	15.4	10.9	8.6	7.9	8.9	8.8
9	turkey	16.5	19.2	30.5	8	17.5	16.3	27.5	6.6	19.7	23.2	23.7	6.9
10	USA	27.8	27.5	38.9	56	23.0	23.9	31.1	44.4	21.1	22.6	30.2	41.9
11	italy	6.7	8.2	5.1	19.7	5.2	6.5	5.2	17.3	3.9	5.5	3.8	13.8
12	UK	4.1	5.6	5.1	17.1	3.7	5.0	4.4	12.9	3.0	4.2	3.7	10.6

no	NAMA NEGARA	Q1'1 2	Q2'1 2	Q3'1 2	Q4'1 2	Q1'1 3	Q2'1 3		Q4'1 3	Q1'1 4	Q2'1 4		Q4'1 4	Q1'1 5	
1	india	147.5	133.8	147.2	166.6	144.7	188.5	146.2	138.1	123.7	151.6	183.1	169.2	150.7	121.5
2	china	168.6	132.1	143.3	155.3	219.8	326.9	229.4	162.6	236.0	184.6	181.0	205.3	219.8	172.5

3	japan	4.0	4.4	4.1	3.7	3.4	3.9	4.7	5.0	3.8	3.7	4.2	4.8	3.2	3.9
4	indonesia	11.6	7.1	9.0	7.6	12.3	10.3	9.6	9.0	11.5	9.1	8.2	7.7	12.1	8.5
5	vietnam	4.6	2.4	1.6	1.8	3.4	3.1	2.7	2.6	3.7	3.1	2.7	3.0	4.4	3.7
6	saudi arabia	11.8	15.9	11.5	9.8	12.3	24.1	16.7	13.3	16.5	18.9	15.0	18.0	17.4	18.8
7	egypt	16.7	14.1	9.4	9.3	16.7	22.7	12.7	12.2	18.0	17.0	10.4	10.6	16.3	14.9
8	UAE	9.8	8.8	11.1	12.3	11.9	13.3	10.6	9.9	13.0	11.4	11.1	9.5	9.3	8.9
9	turkey	16.3	20.4	22.1	7.0	16.7	27.2	23.4	12.6	14.4	16.6	16.9	20.2	10.4	11.6
10	USA	19.3	20.1	27.7	39.9	20.7	24.0	25.3	42.5	21.5	25.0	26.2	43.8	22.2	25.6
11	italy	3.4	4.6	3.1	11.5	3.2	4.3	3.2	10.4	3.0	4.1	3.0	9.7	2.9	4.0
12	UK	2.7	3.6	3.4	10.3	2.9	3.1	3.9	11.2	3.8	4.0	4.9	12.9	4.0	4.1

no	NAMA NEGARA	Q3'1 5	Q4'1 5	Q1'1 6	Q2'1 6	Q3'1 6	Q4'1 6	Q1'1 7	Q2'1 7	Q3'1 7	Q4'1 7	Q1'1 8	Q2'1 8	Q3'18	Q4'18
1	india	214.1	176.0	79.8	89.8	152.7	182.2	123.7	161.0	134.8	182.4	119.2	149.9	148.8	180.1

2	china	184.1	191.1	183.1	149.1	144.1	168.5	179.1	141.1	162.0	183.0	187.5	144.1	176.6	178.0
3	japan	4.4	5.1	3.6	4.0	4.2	5.2	3.3	4.1	4.1	5.1	3.3	4.1	4.0	5.0
4	indonesia	9.3	9.0	10.8	9.4	8.7	9.5	9.2	10.2	9.3	9.9	9.5	11.2	10.3	10.9
5	vietnam	3.5	3.9	4.7	3.5	3.3	3.9	4.6	3.9	3.7	4.3	5.1	4.4	4.1	4.6
6	saudi arabia	16.0	17.4	12.9	13.1	10.8	12.6	10.4	12.0	9.5	12.6	7.5	10.5	11.9	9.5
7	egypt	10.0	10.2	16.7	11.7	7.8	9.0	15.5	12.6	7.4	11.1	10.1	9.8	6.9	9.5
8	UAE	11.8	8.2	6.6	5.8	7.1	6.0	5.7	4.7	6.3	5.3	6.0	5.1	7.4	6.0
9	turkey	12.1	15.0	8.7	9.2	9.3	13.6	8.3	11.1	10.3	11.5	10.1	10.0	7.2	9.2
10	USA	26.5	45.2	22.3	25.8	26.0	44.7	22.7	26.8	27.2	46.9	23.7	28.3	28.3	48.1
11	italy	3.0	9.4	2.8	4.0	3.0	9.2	2.8	3.9	2.9	9.2	2.7	3.9	2.9	9.1
12	UK	4.9	12.9	4.0	4.2	4.8	12.2	3.7	3.8	4.6	11.0	3.8	3.8	4.6	10.4

no	NAMA NEGARA	Q1'19	Q2'19	Q3'19	Q4'19	Q1'20	Q2'20	Q3'20	Q4'20	Q1'21
1	india	125.4	168.6	101.6	149.0	73.9	44.0	60.8	137.3	102.5
2	china	183.6	136.0	158.1	160.4	61.3	90.7	118.5	143.3	191.1
3	japan	3.4	4.2	4.2	5.2	3.1	2.5	3.6	4.7	2.8

4	indonesia	10.1	11.8	8.8	9.8	4.5	4.1	4.4	7.8	6.0
5	vietnam	5.4	4.5	3.6	3.7	4.5	1.6	1.8	2.8	5.1
6	saudi arabia	9.4	9.5	9.5	8.8	6.9	1.9	7.2	6.7	7.8
7	egypt	10.7	9.3	5.4	8.6	9.5	1.3	3.8	6.9	8.3
8	UAE	6.9	5.5	7.0	7.0	6.9	1.7	5.3	5.9	7.1
9	turkey	9.6	9.7	8.4	9.1	8.6	4.0	6.6	6.8	9.0
10	USA	24.0	28.7	29.3	49.2	22.8	18.6	28.2	48.7	24.3
11	italy	2.7	3.8	2.8	8.9	2.0	1.8	2.4	7.5	2.1
12	UK	3.7	3.7	4.4	10.0	2.9	2.0	3.2	7.5	2.1

```

data
plot(data,col="red",pch=16)
library(e1071)
#Create svm model
model <- svm(Y ~ X , data)
#Make a prediction for each x
predictedY <- predict(model, data)
points(data$X, predictedY, col = "red", pch=4)
#TINGGI
#perform a grid search
#kernel radial
set.seed(123)
tuneResult <- tune(svm, Y ~ X, data = data, kernel="radial", ranges = list(epsilon = seq(0,1,0.01),
cost = 2^(2:9)))
print(tuneResult)
tunedModel <- tuneResult$best.model
tunedModelY <- predict(tunedModel, data)
points(data$X, tunedModelY, col = "green", pch=4)
print(tunedModelY)
#kernel polynomial
set.seed(123)
tunepoly <- tune(svm, Y ~ X, data = data, kernel="polynomial", ranges = list(epsilon =
seq(0,1,0.01), cost = 2^(2:9)))
print(tunepoly)
tunedModelpol <- tunepoly$best.model
tunedModelY_pol <- predict(tunedModelpol, data)
points(data$X, tunedModelY_pol, col = "green", pch=4)
print(tunedModelY_pol)

```

```

#kernel linear
set.seed(123)
tuneLin <- tune(svm, Y ~ X, data = data, kernel="linear", ranges = list(epsilon = seq(0,1,0.01),
cost = 2^(2:9)))
print(tuneLin)
tunedModelLin <- tuneLin$best.model
tunedModelY_Lin <- predict(tunedModelLin, data)
points(data$X, tunedModelY_Lin, col = "green", pch=4)
print(tunedModelY_Lin)
#MODEL TERBAIK tinggi
set.seed(123)
model <- svm(Y ~ X, data = data, kernel = "radial", epsilon = 0.57, cost = 4)
x <- c(1:25)
y <- c(72.6, 60.4, 77.1, 74.1, 53.6, 49.2, 58.1, 70.5, 59.5, 59.7, 57.9, 73.6, 59.0, 58.0, 63.3, 71.9, 60.0, 59.6, 51.
3, 63.8, 30.2, 26.3, 37.3, 58.1, 56.9)

DF <- data.frame(x = x, y = y)

nextvalues <- c(14:30)

model <- svm(y ~ x, kernel = "radial", epsilon = 0.57, cost = 4)

predict(model, newdata = data.frame(x = nextvalues))

```