

# Pemodelan *Vector Autoregressive - Support Vector Regression* (VAR-SVR) Untuk Meramalkan Jumlah Uang Yang Beredar di Indonesia

Oleh: Zamni Haquel Alfiyani  
Univeristas Muhammadiyah Semarang

Article history	Abstract
Submission :	One of the main indicators that can be used as a reference to determine the development of a country's economy is the inflation rate. Inflation is influenced by several factors, one of which is the amount of money circulating in society. Modeling that can be used in the money supply data is Vector Autoregressive - Support Vector Regression (VAR-SVR). VAR-SVR modeling is done by making the significant lag variable from the VAR model as input to the SVR model and determining the best parameters using grid search optimization. The purpose of this research is to find the best VAR-SVR model for modeling data on the amount of money in circulation in Indonesia. The best model for VAR is VARIMA (3,1,0) with an AIC value of 14,35267. In VAR-SVR modeling, the best kernel function is the linear kernel, where the best cost value on currency is 0,1 with RMSE of 19401,07, while the best cost value on demand deposit is 100 with RMSE 62917,94. The accuracy rate of forecasting resulted in a small MAPE with a very good category, on data currency is 2,37% while on data demand deposit is 6,52%.
Revised :	
Accepted :	
<b>Keyword:</b> Pemodelan, Uang beredar, <i>Vector Autoregressive - Support Vector Regression</i> (VAR-SVR)	

## PENDAHULUAN

Boediono (2000) menjelaskan bahwa inflasi adalah meningkatnya harga-harga secara umum dan terus menerus yang meluas hingga mengakibatkan kenaikan pada barang lainnya. Inflasi juga dapat dijadikan sebagai salah satu indikator penting yang digunakan untuk melihat kestabilan ekonomi suatu negara. Jika laju inflasi suatu negara terkendali dengan baik (rendah dan stabil), maka akan berdampak baik bagi perekonomian suatu negara. Sedangkan jika tingkat inflasi tidak mampu dikendalikan yaitu terlalu tinggi ataupun terlalu rendah, maka dapat memberikan dampak negatif pada perekonomian negara tersebut. Beberapa faktor yang menyebabkan kenaikan dan penurunan angka inflasi adalah tingginya permintaan atau adanya daya tarik masyarakat yang kuat terhadap suatu barang, naiknya biaya produksi yang dapat mempengaruhi harga barang dan jasa yang dihasilkan, dan bertambahnya uang yang beredar di masyarakat.

Uang beredar adalah jumlah uang yang tersedia dalam perekonomian dan dapat

digunakan untuk membiayai transaksi-transaksi yang dilakukan dalam masyarakat (Sukirno 2000). Jika dilihat secara sempit (M1), uang beredar terdiri dari uang kartal (uang logam dan uang kertas yang biasa kita gunakan) dan uang giral (giro berdenominasi rupiah). Jenis uang tersebut merupakan uang yang bisa ditransaksikan secara langsung.

Bertambahnya jumlah uang yang beredar secara berlebihan akan mendorong peningkatan laju inflasi sehingga dapat mengganggu pertumbuhan ekonomi. Namun, apabila terjadi penurunan jumlah uang beredar yang sangat rendah, maka akan terjadi kelesuan ekonomi. Oleh karena itu, diperlukan suatu model untuk meramalkan jumlah uang beredar di masa yang akan datang agar kestabilan ekonomi dapat tetap terjaga.

Data-data uang yang beredar seperti data uang kartal dan uang giral merupakan beberapa contoh data *time series* dibidang keuangan yang dapat dilakukan pemodelan. Data *time series* (deret waktu) didefinisikan sebagai data-data yang dikumpulkan menurut

urutan waktu dapat berupa urutan hari, minggu, bulan, tahun dan lain sebagainya, sehingga secara singkat data *time series* dapat diartikan sebagai data-data yang disusun dari waktu ke waktu.

Penelitian mengenai jumlah uang beredar di Indonesia pernah dilakukan oleh Rosyidah dkk (2017) menggunakan metode *Vector Autoregressive With Exogenous Variable* (VARX). Model VAR sebenarnya merupakan gabungan dari beberapa model AR (*Autoregressive*), dimana model-model ini membentuk sebuah vektor yang antara variabel-variabelnya (variabel endogen) saling mempengaruhi (Sims, 1972). Sedangkan VARX merupakan model VAR dengan tambahan variabel eksogen atau variabel yang dianggap mempengaruhi variabel endogennya. Dalam penelitiannya, Rosyidah dkk menggunakan 3 variabel endogen yaitu uang kartal, uang kuasi dan surat berharga selain saham, sedangkan tingkat suku bunga Sertifikat Bank Indonesia (SBI) ia gunakan sebagai variabel eksogen. Hasil penelitiannya, diperoleh nilai MAPE yang dihasilkan  $<10\%$  artinya metode VARX memiliki kemampuan peramalan sangat baik sehingga dapat digunakan untuk peramalan periode mendatang. Namun ia juga mengatakan bahwa tidak ada satupun variabel endogen yang dipengaruhi oleh variabel eksogen.

Salah satu penelitian terdahulu terkait pemodelan *Vector Autoregressive* pernah dilakukan oleh Nabila (2016) untuk meramalkan curah hujan di kota Surabaya. Dalam penelitiannya, ia menggabungkan model *Vector Autoregressive* dengan *Support Vector Regression* (VAR-SVR) dan membandingkannya dengan metode *Generalized Space Time Autoregressive - Support Vector Regression* (GSTAR-SVR). Hasil yang didapat adalah Model VAR-SVR relatif memiliki nilai RMSE *out sample* yang lebih kecil dari pada model GSTAR-SVR, sehingga dapat disimpulkan bahwa model terbaik untuk meramalkan curah hujan di Surabaya adalah model VAR-SVR. Pemodelan VAR-SVR dilakukan dengan menjadikan variabel lag signifikan dari model VAR sebagai input pada model SVR dan menentukan parameter terbaik menggunakan optimasi *grid search*. Penelitian lainnya dilakukan oleh Maghfiroh (2018), ia membandingkan model VARX-SVR dengan GSTARX-SVR untuk peramalan arus uang di KPW II BI. Hasil yang

diperoleh adalah GSTARX -SVR lebih baik jika diterapkan pada model linier, sedangkan VARX-SVR akan lebih baik jika diterapkan pada pemodelan hybrid non linier.

Berdasarkan uraian di atas, peneliti ingin menerapkan model *Vector Autoregressive - Support Vector Regression* (VAR-SVR) pada data uang kartal dan uang giral.

## LANDASAN TEORI

### Uang Beredar

Sukirno (Rosyidah dkk, 2017) mengatakan bahwa uang beredar adalah jumlah uang yang tersedia dalam perekonomian dan dapat digunakan untuk membiayai transaksi-transaksi yang dilakukan dalam masyarakat. Jika dilihat secara sempit uang beredar (M1) terdiri atas uang kartal dan uang giro. Uang kartal merupakan uang kertas dan uang logam yang beredar di masyarakat yang dikeluarkan dan diedarkan oleh Bank Indonesia yang berfungsi sebagai otoritas moneter. Bagi masyarakat luas, jenis uang ini lebih sering dikenal dengan sebutan uang tunai, yaitu uang yang ada di tangan masyarakat (di luar bank umum) dan siap dibelanjakan setiap saat, terutama untuk pembayaran-pembayaran dalam jumlah yang tidak terlalu besar. Sedangkan uang giral merupakan uang dalam rekening giro di bank umum yang penarikannya dapat dilakukan sewaktu-waktu hanya dengan menuliskan jumlah uang yang diinginkan pada selebar cek.

### Analisis Multivariate Time Series

Muhtaram (Maghfiroh, 2018) menjelaskan bahwa analisis *time series* adalah salah satu metode peramalan secara matematis dengan menggunakan waktu sebagai acuan, kemudian membuat prediksi dengan menggunakan ekstrapolasi berdasarkan waktu untuk pola-pola tersebut. Tsay (Nabila, 2016) mengatakan bahwa beberapa kasus penelitian yang telah berkembang memerlukan suatu analisis *time series* yang mempertimbangkan berbagai *time series* secara simultan, analisis ini disebut dengan analisis *multivariate time series*. Analisis *multivariate time series* digunakan untuk menganalisis beberapa variabel yang memiliki keterkaitan dengan variabel lainnya yang saling berkaitan.

### Stasioneritas Data

Terdapat dua jenis stasioneritas data yaitu stasioner dalam *mean* dan varians.

Pengujian stasioneritas dalam *mean* dapat dilakukan dengan uji ADF (*Augmented Dickey-Fuller*) dan plot MCCF (*Matrix Cross Correlation Function*). Dimana dikatakan stasioner jika *p-value* pada uji ADF  $< \alpha$  (5%) atau plot MCCF menunjukkan sedikitnya tanda + dan -. Jika data tidak stasioner dalam *mean*, maka dapat dilakukan pembedaan (*differencing*). Sedangkan pengujian stasioner terhadap varians dilakukan dengan uji *Box-cox*, dikatakan stasioner jika nilai *rounded-value* yang dihasilkan adalah 1. Untuk mengatasi data yang tidak stasioner dalam varians dapat dilakukan dengan transformasi.

### Identifikasi Model

Identifikasi model dilakukan dengan melihat visualisasi plot dari MCCF dan MPCCF setelah data stasioner. Hal ini dilakukan dengan melihat lag-lag yang signifikan pada plot-plot tersebut. Plot MCCF digunakan untuk mengidentifikasi model *Vector Moving Average* (VMA) sedangkan plot MPCCF digunakan untuk mengidentifikasi *Vector Autoregressive* (VAR).

### Model Multivariate Time Series

Terdapat beberapa model pada analisis multivariat, diantaranya adalah model *Vector Autoregressive* (VAR), model *Moving Average* (VMA), serta model *Vector Autoregressive Integrated Moving Average* (VARIMA).

### Model Vector Autoregressive (VAR)

Menurut Wei (Ulya, 2019) pemodelan deret waktu dengan menggunakan *Vector Autoregressive* adalah salah satu model peramalan untuk data deret waktu *multivariate* yang sering digunakan karena mudah dan fleksibel jika dibandingkan dengan model lainnya. Model VAR merupakan pengembangan dari model AR dengan melibatkan lebih satu variabel, dimana pada model VAR ini semua variabel dianggap sebagai variabel endogen dan saling berhubungan. Secara umum model VAR (*p*) ditulis sebagai berikut:

$$Y_t = \Phi_1 Y_{t-1} + \dots + \Phi_p Y_{t-p} + e_t$$

dimana:

- $Y_t$  : vektor  $m \times 1$  dari variabel pada waktu ke-t
- $Y_{t-1}$  : vektor  $m \times 1$  dari variabel pada waktu ke-(t-1)

- $\Phi_i$  : matriks parameter *Autoregressive* berukuran ( $m \times 1$ ),  $i = 1, 2, \dots, p$
- $e_t$  : vektor  $m \times 1$  dari *residual* pada waktu ke-t

### Model Moving Average (VMA)

Model *Moving Average* (VMA) merupakan pengembangan atau gabungan dari beberapa model MA yang membentuk sebuah vektor. Secara umum persamaan VMA (*q*) ditulis sebagai berikut:

$$Y_t = a_t - \Theta_1 a_{t-1} - \dots - \Theta_q a_{t-q}$$

dimana:

- $Y_t$  : vektor  $n \times 1$  dari variabel pada waktu ke-t
- $Y_{t-1}$  : vektor  $n \times 1$  dari variabel pada waktu ke-(t-1)
- $\Theta_i$  : matriks parameter *Moving Average* berukuran ( $n \times 1$ ),  $i = 1, 2, \dots, q$
- $e_t$  : vektor  $n \times 1$  dari *residual* pada waktu ke-t

### Model Vector Autoregressive Integrated Moving Average (VARIMA)

Model *Vector Autoregressive Integrated Moving Average* atau yang biasa disebut dengan VARIMA adalah bentuk lain dari model multivariat ARIMA. Secara umum model VARIMA (*p, d, q*) dapat dituliskan dalam bentuk (Wei, 2006):

$$\Phi_p(B)D(B)\dot{Y}_t = \Theta_q(B)e_t$$

dengan  $\dot{Y}_t = (Y_{1,t}, Y_{2,t}, \dots, Y_{m,t})'$  merupakan vektor respon yang terkoreksi nilai rata-rata,  $\Phi_p(B)$  dan  $\Theta_q(B)$  merupakan suatu matriks koefisien AR(*p*) dan MA(*q*),  $D(B)$  merupakan operator proses diferensi yang dinyatakan dengan  $diag((1-B)^{d_1}, (1-B)^{d_2}, \dots, (1-B)^{d_m})$ , dan  $e(t) \sim IIDN(0, \Omega)$ .

### Uji Signifikansi Parameter

Menurut Gujarati (Ayu, 2020) pengujian signifikansi parameter model dilakukan secara parsial menggunakan uji t. Pengujian ini dilakukan untuk mengetahui parameter-parameter yang signifikan pada model dengan hipotesis awal ( $H_0$ ) yaitu parameter tidak signifikan, sedangkan hipotesis alternatifnya ( $H_1$ ) adalah parameter signifikan. Pengambilan keputusan dilakukan dengan membandingkan *p-value* dari hasil pengujian dengan nilai signifikansi ( $\alpha$ ) sebesar 5% atau 0,05. Tolak  $H_0$  apabila *p-value*  $< \alpha$ , sehingga kesimpulan yang diambil ialah parameter

signifikan, dan begitu pula sebaliknya. Apabila terdapat parameter yang tidak signifikan terhadap model, maka perlu dilakukan *restrict*. *Restrict* dilakukan secara bertahap dimulai dari parameter yang memiliki p-value tertinggi sampai semua parameter bernilai kurang dari  $\alpha$  (5%) atau signifikan terhadap model.

### Diagnostic Check Model

Pengujian diagnostik model dilakukan menggunakan uji *white noise* dan uji *multivariate normal*. Pengujian residual *white noise* dilakukan untuk mengetahui apakah residual model saling independen antara satu dengan lainnya. Pengujian pada asumsi ini dapat menggunakan plot MACF dari residual, dimana bersifat *white noise* apabila tidak terdapat lag yang signifikan pada plot tersebut. Selain itu, dapat juga digunakan uji *Portmanteau* yang merupakan pengembangan dari uji L-Jung Box dalam kasus *multivariate*. Pengambilan keputusan dilakukan dengan membandingkan p-value pada beberapa lags hasil pengujian dengan nilai signifikansi ( $\alpha$ ) sebesar 5% atau 0,05. Model bersifat *white noise* apabila p-value pada masing-masing lag tiap model  $> \alpha$ .

Pengujian residual *multivariate normal* digunakan untuk mengetahui apakah residual berdistribusi normal. Pengujian ini dilakukan menggunakan uji *Shapiro-Wilk*, dimana pengambilan keputusan dilakukan dengan membandingkan p-value pada dari hasil pengujian dengan nilai signifikansi ( $\alpha$ ) sebesar 5% atau 0,05. Residual pada model bersifat *multivariate normal* apabila p-value yang dihasilkan bernilai  $> \alpha$ .

### Support Vector Regression

*Support Vector Regression* (SVR) merupakan penerapan dari metode *Support Vector Machine* (SVM) dalam kasus regresi. Konsep SVM menggunakan konsep  $\epsilon$ -insentive *loss function* yang dapat digeneralisasi untuk melakukan pendekatan fungsi yang dikenal dengan SVR (Gunn, 1998). Jika SVM digunakan untuk mencari *hyperplane* (fungsi pemisah) yang terbaik diantara 2 obyek yang tidak terbatas jumlahnya dengan cara memaksimalkan jarak (*margin*) antara dua obyek yang berbeda sedangkan SVR digunakan untuk menemukan suatu fungsi yang memiliki deviasi paling besar  $\epsilon$  dari target aktual  $y_i$ .

Konsep SVR didasarkan pada *structural risk minimization*, yaitu untuk mengestimasi suatu fungsi dengan cara meminimalkan batas atas dari *generalization*

*error*, sehingga SVR mampu mengatasi *overfitting*. Tujuan dari SVR adalah untuk mendapatkan suatu fungsi dengan tingkat kesalahan paling kecil sehingga menghasilkan suatu prediksi yang bagus. Ide dasar dari SVR yaitu dengan menentukan set data yang dibagi menjadi *set training* (*in sample*) dan *set testing* (*out sample*). Kemudian dari *set training* tersebut ditentukan suatu fungsi regresi dengan batasan deviasi tertentu sehingga dapat menghasilkan prediksi yang mendekati dari target aktual. Kelebihan SVR dibanding regresi linier adalah regresi linier menghasilkan fungsi linier yang berupa garis lurus, sedangkan SVR menghasilkan trend data yang bergelombang mengikuti jalur data yang terbentuk sehingga diharapkan hasil prediksi yang didapat lebih akurat.

Fungsi kernel yang dapat digunakan dalam metode SVR adalah sebagai berikut:

1. Linier

$$K(\mathbf{x}, \mathbf{x}^T) = \mathbf{x}^T \mathbf{x}$$

2. Polynomial

$$K(\mathbf{x}, \mathbf{x}^T) = (\mathbf{x}^T \mathbf{x} + 1)^p$$

3. *Radial basis function* (RBF)

$$K(\mathbf{x}_t, \mathbf{x}_u) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x}_t - \mathbf{x}_u\|^2\right)$$

Salah satu cara dalam menentukan parameter optimal pada model SVR adalah menggunakan optimasi *grid search*. Optimasi *grid search* merupakan kombinasi parameter yang diujikan pada suatu model SVR untuk mencari nilai *error* terkecil. Optimasi ini mengidentifikasi parameter optimal dalam data *training*, sehingga model tersebut mampu secara akurat memprediksi data *testing*. Proses ini dilakukan secara *trial and error* hingga didapatkan parameter optimal dengan RMSE terkecil.

### Evaluasi Model

Evaluasi model dilakukan menggunakan beberapa kriteria, yaitu nilai *Root Mean Square Error* (RMSE), *Akaike Information Criterion* (AIC) dan *Mean Absolute Percentage Error* (MAPE). AIC digunakan untuk pemilihan model terbaik VAR dan RMSE digunakan untuk pemilihan model SVR, dimana model terbaik adalah model yang memiliki nilai AIC/RMSE terkecil. Sedangkan nilai MAPE digunakan untuk mengetahui tingkat akurasi hasil peramalan. Berikut ditampilkan tabel kriteria MAPE:

Tabel 1. Kriteria MAPE

MAPE	Pengertian
<10%	Kemampuan Peramalan Sangat Baik
<20%	Kemampuan Peramalan Baik
<30%	Kemampuan Peramalan Cukup Baik
>30%	Kemampuan Peramalan Tidak Akurat

## METODE PENELITIAN

### Sumber Data

Data yang digunakan dalam penelitian ini adalah data kuantitatif. Data kuantitatif merupakan data yang dapat dihitung secara langsung atau didefinisikan sebagai informasi yang disajikan dalam bentuk angka. Sedangkan sumber data yang digunakan adalah data sekunder atau data yang diperoleh peneliti dari sumber yang sudah ada. Dalam penelitian ini, data diperoleh dari publikasi statistik pada sub-bab Keuangan dengan judul "Uang Beredar, 2003-2020" yang dipublikasikan oleh Badan Pusat Statistik (BPS).

### Variabel dan Struktur Data

Tabel 2. Variabel Penelitian

Data	Variabel	Keterangan
Uang Kartal	$Y_{1,t}$	Uang kartal pada bulan ke-t
Uang Giral	$Y_{2,t}$	Uang giral pada bulan ke-t

Tabel 3. Struktur Data

Tahun	Bulan	Uang Kartal	Uang Giral
2010	1	$Y_{1,1}$	$Y_{2,1}$
	2	$Y_{1,2}$	$Y_{2,2}$
	3	$Y_{1,3}$	$Y_{2,3}$
...	...	...	...
	...	...	...
2020	...	...	...
	128	$Y_{1,128}$	$Y_{2,128}$

### Langkah Penelitian

Langkah-langkah dalam penelitian ini yaitu :

1. Menyiapkan data yang akan dianalisis.
2. Melakukan analisis statistika deskriptif pada data jumlah uang yang beredar di Indonesia.
3. Menentukan data *in-sample* dan data *out-sample*, dimana data *in-sample* yaitu data

jumlah uang beredar pada bulan Januari 2010 sampai dengan bulan Juli 2019, kemudian data *out-sample* adalah data jumlah uang beredar pada bulan Agustus 2019 sampai dengan bulan Agustus 2020.

4. Melakukan pengujian stasioneritas pada data uang kartal dan uang giral.
5. Melakukan pemodelan VAR dengan cara:
  - a. Mengidentifikasi orde model VAR pada kedua data menggunakan plot MPCCF.
  - b. Mengestimasi parameter dari model VAR yang didapat.
  - c. Melakukan uji diagnostik model yaitu uji *multivariate normal residual* dan uji *white noise residual*.
  - d. Memilih model terbaik berdasarkan nilai AIC terkecil.
6. Melakukan pemodelan VAR-SVR dengan menjadikan variabel lag yang signifikan dari model VAR sebagai input pada model SVR dan menentukan parameter terbaik menggunakan optimasi *grid search* dengan tahapan sebagai berikut:
  - a. Menentukan fungsi kernel, parameter *cost* dan parameter  $\gamma$  dengan metode optimasi *grid-search*.
  - b. Evaluasi pemilihan model VAR-SVR pada data *out sample* dengan nilai RMSE.
7. Melakukan peramalan jumlah uang yang beredar menggunakan model terbaik VAR-SVR dan menghitung tingkat keakurasian peramalannya dengan nilai MAPE.

## HASIL PENELITIAN dan PEMBAHASAN

### Statistika Deskriptif

Karakteristik data jumlah uang beredar (M1) memiliki persebaran yang sangat beragam, hal ini ditunjukkan dengan nilai standar deviasi yang besar pada data uang kartal dan uang giral yaitu 203208,70 dan 132683,66. Selain itu didapat pula rata-rata data jumlah uang beredar (M1) tertinggi adalah uang giral yaitu sebesar 608822,74 dengan nilai minimum dan maksimum sebesar 278375,58 dan 1098471,48. Sedangkan rata-rata uang kartal adalah 428483,46 dengan nilai minimum dan maksimum sebesar 205083,05 dan 685044,47. Kemudian secara keseluruhan, nilai *skewness* pada data jumlah uang beredar bernilai lebih dari nol atau positif yaitu 0,163 (uang kartal) dan 0,253 (uang giral). Hal ini menunjukkan

tingkat kemiringan grafik persebaran data yang melenceng kekanan. Diperoleh pula nilai kurtosis pada data uang kartal dan uang giral sebesar -1,098 dan -1,008 yang artinya nilai kurtosis  $< 3$  sehingga data-data tersebut berdistribusi *pl atikurtik* (lebih rata).

### Pemodelan *Vector Autoregressive* (VAR)

Pemodelan VAR dilakukan dengan membagi data menjadi data *in sample* dan data *out sample*. Pembagian data dilakukan dengan perbandingan 90:10, yaitu 90% sebagai data *in sample* dan 10% lainnya digunakan sebagai data *out sample*. Sehingga diperoleh data *in sample* adalah data uang beredar (M1) dari bulan Januari 2010 sampai bulan Juli 2019 dengan jumlah data sebanyak 115 data. Sedangkan data *out sample* adalah data uang beredar (M1) pada bulan Agustus 2019 sampai bulan Agustus 2020 dengan jumlah 13 data.

### Uji Stasioneritas

Hasil uji stasioner dalam varians dijelaskan pada Tabel 3. berikut :

Tabel 4. *Boxcox Test*

Data	<i>Rounded-Value</i>	
	Sebelum transformasi	Setelah transformasi
Uang Kartal	0,3471555	1,999924
Uang Giral	1,34649	1,34649

Dari Tabel di atas diperoleh nilai *rounded-value* uji *box.cox* sebelum transformasi pada data uang giral sebesar 1,34649 artinya data tersebut stasioner terhadap ragam. Namun pada data uang kartal diperoleh nilai *rounded-value* sebesar 0,3471555 ( $< 1,00$ ) sehingga perlu dilakukan transformasi hingga nilai *rounded-value* yang didapat sebesar  $\geq 1,00$ . Berdasarkan Tabel kesetaraan transformasi, maka transformasi yang akan dilakukan pada data uang kartal adalah transformasi kedalam bentuk logaritma natural (ln). Pada tabel setelah transformasi, semua nilai *rounded-value* pada data uang beredar (M1) menunjukkan angka  $> 1,000$  sehingga mengartikan data tersebut sudah stasioner dalam varians.

Tabel 5. *Augmented Dickey-Fuller Test*

Data	<i>P-Value</i>	
	Sebelum <i>differencing</i>	Setelah <i>differencing</i>
Uang Kartal	0,5652	0,001
Uang Giral	0,9052	0,001

Berdasarkan Tabel 5, diperoleh nilai *p-value* pada data uang kartal dan uang giral sebelum *differencing* sebesar 0,5652 dan 0,9052 artinya data tersebut tidak stasioner terhadap *mean*, sehingga perlu dilakukan *differencing*. Hasil uji ADF pada data uang beredar (M1) setelah dilakukan *differencing* sekali ( $d=1$ ) menunjukkan bahwa semua nilai *p-value*  $< 0,05$ . Artinya data-data tersebut sudah stasioner dalam *mean*.

### Identifikasi Orde Model VAR

Identifikasi orde dilakukan secara visual menggunakan plot MCCF dan MPCCF. Plot MPCCF digunakan untuk mengidentifikasi orde AR ( $p$ ). Sedangkan plot MCCF digunakan untuk mengidentifikasi orde MA ( $q$ ). Pada penelitian ini, model yang ingin dibentuk adalah model VAR, sehingga identifikasi orde model lebih ditekankan melalui plot MPCCF.

Gambar 1. Plot MPCCF

Berdasarkan plot MPCCF pada Gambar 4.3 menunjukkan signifikan pada lag 1, 2 dan 3. Hal ini menunjukkan adanya dugaan model VARIMA(1,1,0), VARIMA(2,1,0), dan VARIMA(3,1,0).

### Estimasi Parameter Model VARIMA

#### 1. Estimasi Parameter VARIMA (1,1,0)

Tabel 6. Hasil Estimasi Parameter VARIMA (1,1,0)

	Parameter	Estimate	P-value	Variable
y1	AR1_1_1	-0.26811	0.0029	y1(t-1)
	AR1_1_2	6.24E-07	0.0056	y2(t-1)
y2	AR1_2_2	-0.22741	0.0156	y2(t-1)

Tabel di atas merupakan tabel hasil estimasi parameter model VARIMA(1,1,0)

setelah dilakukan *restrict*. Berdasarkan tabel tersebut, terdapat 3 parameter yang signifikan yaitu parameter AR(1,1,1), AR(1,1,2) dan AR(1,2,2).

## 2. Estimasi Parameter VARIMA (2,1,0)

Tabel 7. Hasil Estimasi Parameter VARIMA (2,1,0)

	Parameter	Estimate	P-value	Variable
y1	AR1_1_1	-0.26726	0.0026	y1(t-1)
	AR1_1_2	6.22E-07	0.0052	y2(t-1)
y2	AR1_2_2	-0.22683	0.016	y2(t-1)

Tabel 7 adalah tabel hasil estimasi parameter model VARIMA(2,1,0) setelah dilakukan *restrict*. Dari tabel tersebut, diperoleh 3 parameter yang signifikan yaitu parameter AR(1,1,1), AR(1,1,2) dan AR(1,2,2).

## 3. Estimasi Parameter VARIMA (3,1,0)

Tabel 8. Hasil Estimasi Parameter VARIMA (3,1,0)

	Parameter	Estimate	P-value	Variable
y1	AR1_1_1	-0.4476	0.0001	y1(t-1)
	AR1_1_2	8.22E-07	0.0002	y2(t-1)
	AR2_1_1	-0.32891	0.0006	y1(t-2)
y2	AR2_1_2	7.07E-07	0.0026	y2(t-2)
	AR3_1_1	-0.19694	0.0265	y1(t-3)
	AR3_1_2	9.10E-07	0.0001	y2(t-3)
	AR1_2_2	-0.22549	0.0178	y2(t-1)

Tabel 8 menunjukkan hasil parameter Model VARIMA (3,1,0) yang telah dilakukan *restrict*. Dari 12 parameter yang diujikan, terdapat 7 parameter yang signifikan terhadap model yaitu parameter AR(1,1,1), AR(1,1,2), AR(2,1,1), AR(2,1,2), AR(3,1,1), AR(3,1,2), dan AR(1,2,2).

### Diagnostic Check Model

Estimasi yang telah didapatkan selanjutnya dilakukan pemeriksaan diagnostik yaitu dengan menguji apakah residual memenuhi asumsi identik, independen, dan berdistribusi normal multivariat.

#### 1. Asumsi White Noise

Pengujian asumsi *white noise* dilakukan terhadap nilai residual dari model.

Pengujian asumsi *white noise* residual pada penelitian ini dilakukan menggunakan uji *Multivariate Portmanteau statistics*. Hasil pengujian Portmanteau ditampilkan pada Tabel 9.

Tabel 9. Hasil Pengujian Portmanteau

Model	Lags	P-Value
VARIMA(1,1,0)	1	0.58331
	2	0.00313
	3	0.006
	4	0.0037
	5	0.00998
VARIMA(2,1,0)	1	0.58758
	2	0.00353
	3	0.00659
	4	0.00438
	5	0.01135
VARIMA(3,1,0)	1	<b>0.74675</b>
	2	<b>0.26815</b>
	3	<b>0.4608</b>
	4	<b>0.57558</b>
	5	<b>0.7266</b>

Model dikatakan memenuhi asumsi *white noise* apabila nilai *p-value* pada kelima lags tersebut bernilai  $> 0,05$  ( $\alpha$ ). Berdasarkan tabel diatas, hanya model VARIMA(3,1,0) yang kelima lagsnya mempunyai nilai *p-value*  $> 0,05$ , sehingga hanya residual pada model VARIMA(3,1,0) yang memenuhi asumsi *white noise*.

#### 2. Asumsi Multivariate Normal

Pengujian asumsi *multivariate normal* residual pada penelitian ini menggunakan uji *Shapiro Wilk* dimana dikatakan normal apabila nilai *p-value* yang dihasilkan  $> 0,05$ . Hasil pengujian *multivariate normal* ditampilkan pada Tabel 10.

Tabel 10. Hasil Pengujian Multivariat Normal

Model	P-value
VARIMA (1,1,0)	$5.439 \times 10^{-5}$
VARIMA (2,1,0)	$5.602 \times 10^{-5}$
VARIMA (3,1,0)	$3.763 \times 10^{-6}$

Tabel 10 merupakan tabel hasil pengujian *multivariate normal* menggunakan Shapiro Wilk. Berdasarkan

tabel tersebut, nilai *p-value* yang diperoleh pada masing-masing model VARIMA (1,1,0), VARIMA (2,1,0) dan VARIMA (3,1,0) adalah  $5.439 \times 10^{-5}$ ,  $5.602 \times 10^{-5}$ , dan  $3.763 \times 10^{-6}$ . Ketiga model tersebut menghasilkan nilai *p-value* kurang dari  $\alpha$  (0,05). Maka dapat disimpulkan bahwa ketiga model tersebut tidak memenuhi asumsi distribusi *multivariate normal*. Pengujian ini bisa diabaikan karena hal paling penting dalam peramalan adalah kemampuan model dalam melakukan peramalan (Armstrong, 2007) dan (Kostenko dan Hyndman, 2008).

### Pemilihan Model Terbaik VAR

Kriteria pemilihan model yang digunakan dalam penelitian ini adalah nilai *Akaike's Information Criterion* (AIC). Dimana model terbaik merupakan model dengan nilai AIC terkecil.

Tabel 11. Nilai AIC

Model	AIC
VARIMA (1,1,0)	14,42659
VARIMA (2,1,0)	14,43373
<b>VARIMA (3,1,0)</b>	<b>14,35267</b>

Berdasarkan tabel 11, nilai AIC terkecil terdapat pada model VARIMA(3,1,0) yaitu sebesar 14,35267, sehingga model yang akan digunakan untuk pemodelan VAR-SVR adalah model VARIMA(3,1,0).

### Pemodelan *Vector Autoregressive – Support Vector Regression*(VAR-SVR)

Pemodelan VAR-SVR pada penelitian ini menggunakan metode *grid search* dalam penentuan parameter yang digunakan. Hal ini dilakukan untuk mendapatkan hasil global yang optimum. Terdapat tiga parameter yang dimiliki model SVR yaitu parameter *epsilon*, *cost* dan *gamma*.

Input model VAR-SVR yang digunakan adalah variabel yang signifikan pada model terbaik VAR yaitu VARIMA (3,1,0). Sehingga lag-lag yang signifikan pada model tersebutlah yang dijadikan input pemodelan VAR-SVR. Pemodelan VAR-SVR dilakukan secara terpisah pada masing-masing data.

### Pemodelan VAR-SVR Uang Kartal

Pemodelan VAR-SVR dilakukan menggunakan lag-lag yang signifikan pada model VARIMA (3,1,0). Pemodelan SVR dilakukan dengan mencoba beberapa fungsi kernel, parameter *cost* dan parameter  $\gamma$ . Untuk nilai epsilon ( $\epsilon$ ) diasumsikan sebesar 0,1 dimana nilai tersebut merupakan default dari *software* R. Sedangkan parameter *Cost* dan  $\gamma$  ditentukan melalui optimasi *grid search* dengan rentang nilai sebesar 0,01 - 1000.

Tabel 12. Hasil Pencarian RMSE Terkecil Untuk Data Uang Kartal

Fungsi Kernel	Epsilon	Gamma	Cost	RMSE
<b>Linear</b>	<b>0,1</b>	-	<b>0,1</b>	<b>19401,07</b>
Polynomial	0,1	-	100	423456,8
Radial	0,1	0,1	10	25893,02

Berdasarkan 12, didapatkan nilai C terbaik pada fungsi kernel linear dan polynomial adalah 0,1 dan 100 dengan RMSE sebesar 19401,07 untuk kernel linear dan 423456,8 untuk kernel polynomial. Sedangkan untuk fungsi kernel radial, diperoleh nilai C dan  $\gamma$  terbaik sebesar 10 dan 0,1 dengan nilai RMSE sebesar 25893,02. Pemilihan kernel terbaik dipilih menggunakan RMSE terkecil, sehingga fungsi kernel yang digunakan untuk proses peramalan adalah fungsi kernel linear.

### Pemodelan VAR-SVR Uang Giral

Pemodelan VAR-SVR dilakukan dengan melakukan *trial and error* untuk mendapatkan nilai RMSE terkecil. Hal ini dilakukan dengan mencoba beberapa fungsi kernel, parameter *cost* dan parameter  $\gamma$ . Untuk nilai epsilon ( $\epsilon$ ) diasumsikan sebesar 0,1 dimana nilai tersebut merupakan default dari *software* R. Sedangkan parameter *Cost* dan  $\gamma$  ditentukan melalui optimasi *grid search* dengan rentang nilai sebesar 0,01 - 1000.

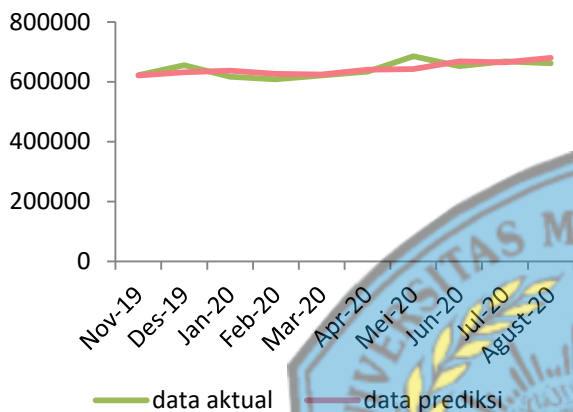
Tabel 13. Hasil Pencarian RMSE Terkecil Untuk Data Uang Giral

Fungsi Kernel	Epsilon	Gamma	Cost	RMSE
<b>Linear</b>	<b>0,1</b>	-	<b>100</b>	<b>62917,94</b>
Polynomial	0,1	-	0,01	496327,9
Radial	0,1	0,1	100	86771,31



Dari tabel di atas, diperoleh nilai C terbaik pada fungsi kernel linear dan polynomial adalah 100 dan 0,01 dengan RMSE sebesar 62917,94 untuk kernel linear dan 496327,9 untuk kernel polynomial. Sedangkan untuk fungsi kernel radial, diperoleh nilai C dan  $\gamma$  terbaik sebesar 100 dan 0,1 dengan nilai RMSE sebesar 86771,31. Pemilihan kernel terbaik dipilih menggunakan RMSE terkecil, sehingga fungsi kernel yang digunakan untuk proses peramalan pada uang giral adalah fungsi kernel linear.

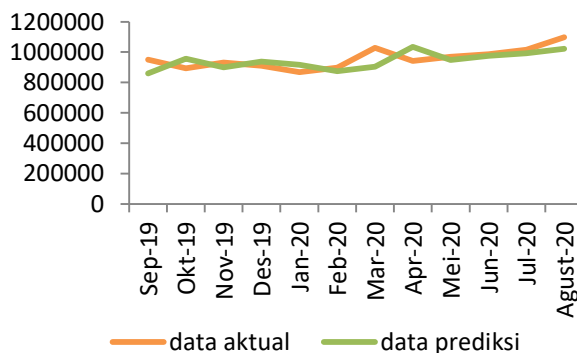
### Peramalan VAR-SVR Uang Kartal



Gambar 2. Plot Hasil Peramalan Uang Kartal

Grafik diatas merupakan perbandingan antara data aktual dan hasil peramalan uang kartal. Dimana prediksi jumlah uang kartal tertinggi ada pada bulan Agustus 2020 yaitu sebesar 679871,3 dan terendah pada bulan November 2019 yaitu 620389,2 dengan MAPE yang dihasilkan sebesar 2,37%.

### Peramalan VAR-SVR Uang Giral



Gambar 3. Plot Hasil Peramalan Uang Giral

Gambar 3 menunjukkan perbandingan antara data aktual dan hasil peramalan uang giral. Dimana prediksi jumlah uang giral tertinggi ada pada bulan April 2020 yaitu

sebesar 1034828,3 dan terendah pada bulan September 2019 yaitu 859713,5 dengan nilai MAPE sebesar 6,52%.

## SIMPULAN dan SARAN

### Simpulan

Berdasarkan hasil analisis yang sudah dijelaskan, didapatkan beberapa kesimpulan sebagai berikut:

1. Karakteristik data jumlah uang beredar (M1) memiliki persebaran yang sangat beragam, hal ini ditunjukkan dengan nilai standar deviasi yang besar pada data uang kartal dan uang giral yaitu 203208,70 dan 132683,66. Selain itu melalui plot data pada gambar 4.1 dan 4.2, diketahui pula bahwa data uang kartal dan uang giral mengalami kenaikan setiap tahunnya. Kemudian secara keseluruhan, nilai *skewness* pada data jumlah uang beredar bernilai lebih dari nol atau positif yaitu 0,163 (uang kartal) dan 0,253 (uang giral). Hal ini menunjukkan tingkat kemiringan grafik persebaran data yang melenceng kekanan.
2. Pemodelan VAR-SVR terbaik pada peramalan jumlah Uang beredar (M1) di Indonesia menggunakan fungsi kernel linear, dimana pada data uang kartal diperoleh cost terbaik adalah 0,1 dengan RMSE sebesar 19401,07. Sedangkan pada data uang giral diperoleh nilai cost terbaik yaitu 100 dengan nilai RMSE sebesar 62917,94.
3. Tingkat akurasi pemodelan VAR-SVR pada jumlah uang beredar di Indonesia menghasilkan MAPE yang kecil dengan kategori sangat baik yaitu pada data uang kartal sebesar 2,37% sedangkan pada uang giral sebesar 6,52%.

### Saran

Dalam penelitian tugas akhir ini tidak memperhatikan orde *Moving Average* (MA) dan data outlier, sehingga disarankan untuk penelitian selanjutnya menggunakan metode yang bisa memperhatikan data outlier (variabel eksogenus) dan orde MA sebagai input series seperti pada model VARIMA atau VARIMAX.

### Daftar Pustaka

Afrizal. 2017. Analisis Kausalitas Inflasi dan Jumlah Uang Beredar di Indonesia Periode

- Tahun 2000.1-2014.4. *Jurnal Ekonomi Bisnis dan Kewirausahaan*, Vol. 6, No. 3. 236-250
- Armstrong, J.S. 2007. Significance Tests Harm Progress in Forecasting. *International Journal of Forecasting*. (23). pages:321-327.
- Anggarini, D. T. 2016. Analisis Jumlah Uang Beredar di Indonesia Tahun 2005-2014. *Moneter*, Vol. III, No. 2, Oktober 2016. 161-169
- Asyiva, A. 2019. *Prediksi Laju Inflasi Indonesia Menggunakan Metode Support Vector Regression dengan Kernel Radial Basis Function*. Jakarta:Universitas Hidayatullah Jakarta
- BI. 2020. Bank Indonesia Bank Sentral Republik Indonesia. <https://www.bi.go.id/id/publikasi/perkembangan/Default.aspx> diakses pada tanggal 22 November 2020.
- BPS. 2020. Badan Pusat Statistik. <https://www.bps.go.id/indicator/13/123/1/uang-beredar.html> diunduh pada tanggal 22 November 2020
- Boediono. 2000. *Ekonomi Moneter*. Edisi 3. Yogyakarta: BPFE.
- C, F. R. 2018. *Peramalan Tingkat Suku Bunga Pasar Uang Antar Bank (PUAB) Menggunakan Metode Vector Autoregressive Exogenous (VARX)*. Makassar:Universitas Islam Negeri Alauddin Makassar
- Cahyani, E dan Lisnur, W. 2020. Pemodelan Vector Autoregressive X (VARX) untuk Meramalkan Impor Ekspor Migas dan Non Migas Di Indonesia. *Prosiding Statistika Vol 6, No. 2 Tahun 2020*. 41-48
- Cahyono, R. E., Judi P. S. dan Suhatati T. 2019. Analisis Kinerja Metode Support Vector Regression (SVR) dalam Memprediksi Indeks Harga Konsumen. *Jurnal Teknologi Informasi dan Multimedia*, Vol. 1, No. 2, Agustus 2019. 106-116
- Faroh, R. A. 2016. *Penerapan Model Fuzzy Time Series – Markov Chain Untuk Peramalan Inflasi*. Malang:Universitas Islam Negeri Maulana Malik Ibrahim Malang
- Fadilah, A. N. 2020. *Penerapan Metode Neural Network Pada Model Vector Autoregressive (VAR-NN)*. Malang:Universitas Brawijaya
- Hanurowati, N., Moch. A. M. dan Alan P. 2016. Pemodelan dan Permalan Indeks Harga Saham Gabungan (IHSG), Jakarta Islamic Index (JII), dan Harga Minyak Dunia Brent Crude Oil Menggunakan Metode Vector Autoregressive Exogenous (VARX). *Jurnal Gaussian Vol 5, No. 4, Tahun 2016*. 683-693
- Hendayanti, N. P. N. dan Maulida N. 2018. Pemodelan Inflasi, Uang Beredar, dan Nilai Tukar Rupiah dengan VARX. *Seminar Nasional Sistem Informasi dan Teknologi Informasi 2018*. 974-980
- \_\_\_\_\_. dan \_\_\_\_\_. 2017. Pemodelan Jumlah Uang Beredar dan Inflasi Nasional dengan Vector Error Correction Model (VECM). *Jurnal Varian Vol. 1, No. 1, September 2017*. 1-9
- Kostenko, A.V., Hyndman, R.J. 2008. Forecasting without Significance Tests?
- Luwihadi, N. L. A. dan Sudarsana A. 2017. Determinan Jumlah Uang Beredar dan Tingkat Inflasi di Indonesia Periode 1984-2014. *EP-Jurnal EP Unud*, 6[4]. 533-563
- Maghfiroh, B. 2018. *Model Hybrid Vector Autoregressive-Support Vector Regression dan Generalized SpaceTime Autoregressive-Support Vector Regression with Exogenous Variables untuk Peramalan Arus Uang di KPW II BI*. Surabaya:Institut Teknologi Sepuluh November Surabaya
- Nabila, F. S. 2016. *Pemodelan Vector Autoregressive - Support Vector Regression (VAR-SVR) dan Generalized Space Time Autoregressive - Support Vector Regression (GSTAR-SVR) Untuk Peramalan Curah Hujan di Kota Surabaya*. Surabaya:Institut Teknologi Sepuluh November Surabaya
- Prahatama, A., Agus R. dan Tiani W. U. 2019. Pemodelan Vector Autoregressive (VARX) Pada Nilai Inflasi Terhadap PDRB di Jawa

Tengah. *Statistika*, Vol 7, No. 2, November 2019. 133-136

Pratama, R. I. H. dan Dewi R. S. S. 2018. Model Runtun Waktu Vector Autoregressive Moving Average With Exogenous Variable (VARMAX). *KNPMP III 2018*. 490-497

Purnama, D. I. dan Siti S. 2020. Support Vector Regression (SVR) Model for Forecasting Number of Passengers on Domestic Flights at Sultan Hasanudin Airport Makassar. *Jurnal Matematika, Statistika & Komputasi Vol. 16, No. 3, 391-403, May, 2020*. 391-403

Purwinda, I. 2018. *Estimasi Parameter Model Vector Autoregressive Menggunakan Metode Ordinary Least Square*. Malang: Universitas Islam Negeri Maulana Malik Ibrahim Malang

Rosyidah, H., Rita R. dan Alan P. 2017. Pemodelan Vector Autoregressive X (VARX) Untuk Meramalkan Jumlah Uang Beredar Di Indonesia. *Jurnal Gaussian Vol 1, No.3, 2017*. 333-343

Solikin dan Suseno. 2002. Uang Pengertian, Penciptaan, dan Peranannya dalam Perekonomian. Bank Indonesia

Ulya, A. 2019. Peramalan Harga Saham Penutupan Menggunakan Metode *Vector Autoregressive Moving Average* (VARMA). Malang: Universitas Islam Negeri Maulana Malik Ibrahim Malang

