

Pemodelan *Time Series* Multivariat secara Automatis

Siana Halim¹, Arif Chandra¹

Abstract: We constructed an automatic multivariate time series algorithm and implemented that algorithm into R-package. Four instruments in used are vector auto regressive (VAR), structural vector auto regressive (SVAR), vector error correction model (VECM), and structural vector error correction (SVEC). VAR and VECM are employed to estimate and construct models and, subsequently, predict the future values of an object. SVAR and SVEC serve to analyze innovative structures of a model. VAR and SVAR can be implemented only to stationary data whilst VECM and SVEC can be applied to non-stationary inputs. Based on this package, all the aforesated models are conclusively able to identify dynamic relationship of endogenous variabel in a model well.

Keywords: Multivariate time series, VAR, SVAR, VECM, SVEC

Pendahuluan

Telah umum diketahui bahwa nilai suatu peramalan (*forecasting*) merupakan landasan untuk menentukan keputusan untuk berproduksi ataupun berinvestasi (Hadi [4]). Tak heran, saat ini ada berbagai macam perangkat lunak (*software*) yang menawarkan kemudahan untuk melakukan peramalan ini. Diantaranya adalah, Eviews, Minitab, SPSS. Namun demikian, perangkat lunak ini menuntut adanya pengetahuan statistika yang kuat dari para penggunanya agar mereka mendapatkan hasil peramalan yang dapat dipercayai. Adanya keterbatasan yang tersebut, memberikan ide untuk membuat suatu perangkat lunak yang memberikan hasil peramalan secara otomatis, sehingga seseorang tanpa pengetahuan statistika yang dalam, terutama dibidang analisa ataupun financial *time series* mampu mengoperasikannya.

Nilai peramalan pada sebuah objek seringkali tidak hanya dipengaruhi oleh sebuah *time series* saja, namun dapat tergantung pada *time series* lainnya. Untuk itulah, pada penelitian ini akan dibangun sebuah *automatic multivariate forecasting R package*. Pemodelan *time series* multivariat dilakukan dengan menggunakan pendekatan ekonometrik. Sims [9] mengembangkan *vector auto regressive* (VAR), yang merupakan model peramalan *time series* multivariat yang paling sering digunakan untuk memprediksi data stasioner. VAR kemudian mengalami perkembangan sehingga mampu membangun *vector error*

correction model (VECM) dan *structural vector error correction* (SVEC) yang digunakan untuk menginterpretasi hubungan kontemporer variabel. Model ini dinamakan dengan *structural vector auto regressive* (SVAR). Pada waktu yang hampir bersamaan, Granger [3] menemukan konsep kointegrasi yang mencari relasi linear antar variabel pada data non-stasioner. Konsep ini selanjutnya digunakan untuk menginterpretasi hubungan kontemporer variabel.

Data sebelum dimodelkan akan mengalami identifikasi awal, kemudian berlanjut ke estimasi parameter, analisis struktural, dan *diagnostic checking*. Estimasi parameter terbaik untuk masing-masing model dilakukan dengan menggunakan nilai *maximum log-likelihood* yang meminimalkan hasil residual. Model terbaik akan digunakan untuk memprediksi nilai masa mendatang. Pembentukan model akan dibangun menggunakan *software* R 2.11.2, yang merupakan kelanjutan dari package peramalan *time series* univariat secara otomatis (Halim, *et al.* [5])

Metodologi Penelitian

Pemodelan *package time series* multivariat secara otomatis ini, merupakan kelanjutan dari package serupa namun untuk *time series* univariat (Halim *et al.* [5]). Pada dasarnya adaptasi yang dilakukan tidak jauh berbeda. Paparan dari adaptasi tersebut dapat diikuti pada bagian ini.

Pada awalnya, stasioneritas data yang diinputkan ke dalam *package* akan diuji menggunakan Automatic Dickey Fuller (ADF) test (Harris dan Sallis [6]) untuk setiap peubah. Sebuah data dikatakan stasioner jika *mean*, varian, *covariance* dari *time series* konstan untuk semua periode dan tidak mem-

¹ Fakultas Teknologi Industri, Jurusan Teknik Industri, Universitas Kristen Petra. Jl. Siwalankerto 121-131, Surabaya 60236, Indonesia, Email: halim@petra.ac.id,

Diterima 18 November 2010; revised 1 5 Mei 2011; Accepted 20 Mei 2011.

punyai fluktuasi periodik. Kestasioneran sebuah data dapat dilihat dari perilaku *autocorrelation function* (ACF) atau *partial autocorrelation function* (PACF) data tersebut. Selanjutnya jika data tersebut stasioner, maka data tersebut akan dimodel dengan menggunakan VAR yang dapat diperbaiki lagi dengan SVAR. Namun bila data tersebut tidak stasioner, maka nonstasioner modelah yang akan digunakan untuk memodelkannya. Adapun nonstationer model yang akan digunakan adalah VECM ataupun SVEC.

Resume dari beberapa teori yang akan digunakan dalam pemodelan tersebut di atas akan disampaikan pada sub bagian berikut. Detail dari penjelasan ini dapat dilihat di Luetkepohl [7], Brooks [2].

Time Series Multivariat

Time series multivariate memodelkan peubah-peubah yang berkorelasi dan tercatat dari waktu ke waktu. Peubah tersebut dinotasikan sebagai berikut $y_{1t}, y_{2t}, \dots, y_{Nt}$; dimana $y_{it}, i = 1, \dots, N$ adalah peubah ke- i yang dicatat pada saat t . Prediksi pada peubah N pada saat $T + h$ dapat dituliskan sebagai fungsi berikut

$$\hat{y}_{N,T+h} = f_N(y_{1,T}, \dots, y_{N,T}, y_{1,T-1}, \dots, y_{N,T-1}) \quad (1)$$

Tujuan utama dari pemodelan *time series* multivariat adalah menentukan estimasi fungsi yang tepat sehingga fungsi tersebut dapat digunakan untuk memprediksi nilai mendatang (*future value*) dengan baik; untuk semua peubah di dalam sistem.

Model untuk Data Stasioner

Model untuk data multivariat stasioner yang akan diulas pada bagian ini adalah *Vector Auto Regressive* (VAR) dan *Struktural Vector Auto Regressive* (SVAR).

Vector Auto Regressive Model

Model VAR dapat menjelaskan peubah endogen dari data masa lalu peubah tersebut dan peubah endogen lainnya. Model VAR(p); p adalah orde dari model, dapat ditulis:

$$\hat{y}_{n,T+h} = \nu + \alpha_{n1,1}y_{1,T} + \alpha_{n2,1}y_{2,T} + \dots + \alpha_{nN,1}y_{N,T} + \alpha_{n1,p}y_{1,T-p+1} + \dots + \alpha_{nN,p}y_{N,T-p+1} \quad (2)$$

$n = 1, \dots, N$

dimana $\alpha_{n1,1}, \dots, \alpha_{nN,p}$ adalah parameter koefisien yang harus diestimasi.

Secara umum, penulisan persamaan (2) dapat dibentuk menjadi:

$$y_t = \nu + A_1y_{t-1} + \dots + A_p y_{t-p} + u_t, t = 0, \pm 1, \pm 2, \dots \quad (3)$$

dengan $y_t = (y_{1,t}, \dots, y_{N,t})'$, transpose dari vektor peubah; $A_i, i = 1, \dots, p$ adalah koefisien matriks berukuran ($K \times K$) dan u_t adalah proses berdimensi K , dengan $E(u_t) = 0$ dan memiliki matriks kovarians $E(u_t u_t') = \Sigma_u$ definit positif (*white noise*). Ada dua hal utama yang harus diestimasi pada model di atas, yaitu p yang dapat menunjukkan model terbaik dan tentu saja matriks koefisien $A_i, i = 1, \dots, p$. Kriteria pemilihan orde terbaik dijelaskan secara singkat di bawah ini, sedangkan estimasi matriks koefisien $A_i, i = 1, \dots, p$ dapat dilihat secara detail pada Luetkepohl [7].

Pemilihan Orde Vector Auto Regressive

Pada *package* ini digunakan empat kriteria untuk memilih orde (p) terbaik, yaitu: *Final Prediction Error* (FPE), *Akaike Information Criterion* (AIC), *Hannan-Quinn Criterion* (HQ), *Schwarz Information Criterion* (SIC). Seperti halnya pada *time series* univariat, alat (*tool*) yang digunakan untuk menentukan nilai p adalah partial auto corelation function (PACF).

Setelah mendapatkan orde p terbaik, maka model VAR(p) yang terbentuk perlu diagnosa terhadap persyaratan stabilitas dan normalitas. Stabilitas di dalam model VAR diperlukan, sebagaimana dengan uji stasioneritas pada model AR. Stabilitas ini adalah uji stasioneritas secara bersama-sama pada peubah multivariat.

Stability dan Normality Condition

Suatu model dikatakan stabil jika memenuhi persamaan:

$$\det(I_N - A_1 y - \dots - A_p y^p) \neq 0, |y| \leq 1 \quad (4)$$

Stabilitas terjadi jika *reverse characteristic polynomial* dari model tidak mempunyai *roots* di dalam dan pada *unit circle* (semua nilai *eigen* < 1). Kondisi normalitas pada data diuji dengan menggunakan *Jarque-Bera test*.

$$JB = N/6 (S^2 + 1/4 K^4) \quad (5)$$

dengan N adalah jumlah observasi, S dan K adalah sampel *skewness* dan *kurtosis* secara berturut-turut. Statistik JB asimtotik terhadap distribusi chi-square dengan dua derajat kebebasan (*degree of freedom*).

Jika data tidak memenuhi kedua persyaratan pertama ini maka *package* akan memberikan peringatan dan menghentikan proses. Namun, bila kedua syarat tersebut terpenuhi, maka akan dilakukan analisa struktural terhadap VAR.

Analisis Struktural terhadap VAR

Uji struktural diperlukan untuk mengetahui hubungan kausalitas (saling memberikan pengaruh) antar peubah. Digunakan *Granger-causality test* untuk menguji kausalitas pada data (Granger [3]). Bila syarat kausalitas ini terpenuhi maka pemilihan model VAR terbaik dapat dilakukan, namun bila tidak maka sekali lagi *package* akan memberikan peringatan dan proses pemodelan berhenti.

Uji diagnostik terhadap model terbaik beserta analisa terhadap *impulse response function* (IRF) dan *Forecast Error Variance decomposition* (FEVD) selanjutnya dilakukan terhadap model terpilih.

Kelemahan model VAR adalah tidak mampu menangkap adanya pergerakan deterministik data *time series*. Oleh karena itu, *Structural Vector Auto Regressive* (SVAR) dibangun untuk menganalisis pergerakan deterministik model VAR.

Structural Vector Auto Regressive Model

Model SVAR dapat dituliskan

$$Ay_t = A_1^*y_{t-1} + \dots + A_p^*y_{t-p} + BU_t, t = 0, \pm 1, \pm 2, \dots \quad (6)$$

Dua tipe SVAR yang dapat diestimasi dengan adanya penambahan pembatas pada matriks A atau B adalah (a) Model A: B didefinisikan sebagai I_N , (b) Model B: A didefinisikan sebagai I_N dengan minimum jumlah pembatas untuk identifikasi model A dan B adalah $N(N-1)/2$.

Langkah selanjutnya adalah sama, yaitu menentukan model SVAR terbaik dan uji diagnostik. Bila semua uji tersebut dapat terpenuhi maka *package* akan menyajikan model terbaik. Selain itu, *package* juga memberikan prediksi h lag ke depan sesuai permintaan pengguna, beserta dengan 95% interval keyakinan (*default* namun dapat diubah). Rangkaian ini mengakhiri pemodelan *time series* multivariat secara otomatis untuk data stasioner. Pada subbab berikut akan dipaparkan pemodelan serupa namun untuk data non-stasioner.

Model untuk Data Nonstasioner

Pada data multivariat, nonstasioneritas dapat terjadi pada semua peubah atau hanya pada sebagian saja dari peubah yang ada. Bila peubah tersebut seluruhnya nonstasioner, maka pemodelan dapat ditangani dengan model-model *Vector Error Correction* (VEC) ataupun *Structural Vector Error Correction* (SVEC). Namun bila hanya sebagian saja dari peubah tersebut yang stasioner, terdapat dua pilihan untuk memodelkan peubah seperti ini.

Kedua pilihan tersebut adalah pertama, memodelkan terlebih dahulu gabungan peubah stasioner dan non stasioner ke dalam model VAR, SVAR kemudian dilanjutkan dengan model VEC dan SVEC. Tentu saja prosedur ini akan memakan waktu lebih lama, namun diyakini lebih tangguh serta memberikan model yang lebih baik. Pilihan kedua adalah memodelkan gabungan tersebut secara langsung ke dalam model VECM dan SVEC.

Kedua pilihan ini disediakan oleh *package time series* multivariat.

Pada data nonstasioner diperlukan uji kointegrasi antar peubah-peubahnya. Uji kointegrasi dilakukan dengan menggunakan prosedur Johansen (Harris and Sallis, [6]). Bila peubah-peubah dalam data tidak berkointegrasi, maka *package* akan memberikan peringatan dan pemodelan berhenti. Namun, bila persyaratan ini terpenuhi pemodelan dengan VECM dapat dilakukan.

Vector Error Correction Model

Vector error correction model adalah model untuk menganalisis data *multivariate time series* yang tidak stasioner. Model VAR yang memiliki hubungan kointegrasi secara linear akan berubah menjadi model VECM, yaitu:

$$\Delta y_t = \alpha \beta^T y_{t-1} + \Gamma_1 \Delta y_{t-1} + \dots + \Gamma_{p-1} \Delta y_{t-p+1} + U_t$$

$$\Gamma_i = -(I - A_1 - \dots - A_i) \quad (7)$$

Parameter α dan β mempunyai dimensi $N \times r$, (N : jumlah peubah dan r : derajat kointegrasi). Derajat kointegrasi menunjukkan berapa panjang hubungan jangka panjang di antara peubah y_t dari model. Salah satu syarat agar model VECM dapat dibangun selain model tidak stasioner adalah ter-kointegrasi. Granger [3] mendefinisikan kointegrasi dengan masuknya vector β ke dalam sebuah persamaan regresi ($y_t = \mu_t + \beta x_t$). Sedangkan derajat kointegrasi ditentukan dengan menggunakan *Johansen procedure*.

Diagnostik tes dan uji yang lain seperti halnya pada model stasioner akan dilakukan pada bagian ini, sebelum model SVEC dibentuk.

Structural Vector Error Correction Model

Model SVEC dibangun dikarenakan informasi yang terdapat di dalam properti kointegrasi dari peubah tidak mengidentifikasi *restrictions* (batasan) pada *structural shock*. Pada SVEC ini diasumsikan model B yang akan digunakan. Model SVEC dapat dituliskan sebagai berikut:

$$\begin{aligned} \Delta y_t &= \alpha\beta^T y_{t-1} + \Gamma_1 \Delta y_{t-1} + \dots + \Gamma_{p-1} \Delta y_{t-p+1} + B\varepsilon_t \\ \varepsilon_t &\sim \mathcal{N}(0, I_N); \Delta y_t = y_t - y_{t-1}; \\ \Gamma_i &= -(I - A_1 - \dots - A_i) \end{aligned} \quad (8)$$

Pada model SVEC diperlukan batasan sebanyak $N(N-1)/2$.

Pada akhir dari pemodelan ini IRF dan FEVD akan dianalisa, dan laporan hasil akhir beserta model terbaik baik itu stasioner ataupun non stasioner akan diberikan pada pengguna. Alur pemodelan time series multivariat secara lengkap dapat dilihat pada Gambar 1.

Resume tentang *impulse response* dan *variance decomposition* diulas di bagian akhir dari metodologi penelitian ini, agar tidak mengganggu bagan utama pada pemodelan time series multivariat.

Inovasi dalam Model *Time Series* Multivariat *Impulse Response*

Impulse response dipahami sebagai fungsi dinamis untuk melacak pengaruh suatu *shock* yang terjadi terhadap peubah endogen di dalam sistem. *Impulse response* berfungsi untuk mencari reaksi dari peubah dependen di dalam model VAR, SVAR, VECM, ataupun SVEC terhadap *shock* untuk setiap peubah di dalam model tersebut. *Shock* yang terjadi pada peubah ke-*i* tidak hanya secara langsung berdampak pada nilai peubah ke-*i* tersebut, namun juga mengakibatkan pengaruh kepada semua peubah endogen yang ada dalam struktur dinamis model.

Variance Decomposition

Variance decomposition bertujuan memisahkan dampak masing-masing *shock* secara individual terhadap respon yang diterima sebuah peubah. Metode ini akan memberikan proporsi terhadap pergerakan di dalam peubah dependen yang berhubungan langsung dengan *shock* pada peubah itu sendiri, dan juga terhadap *shock* lain pada peubah lainnya. Sebuah *shock* terhadap peubah ke-*i* selain secara langsung mempengaruhi peubah itu sendiri, maka *shock* tersebut juga akan mempengaruhi semua peubah di dalam struktur dinamis model VAR yang dibangun.

Hasil dan Pembahasan

Deskripsi Data

Data yang digunakan adalah data Canada (Pfaff [8]). Data Canada berisi empat peubah sebagai indikasi perekonomian Canada dari tahun 1980 kuartal pertama hingga tahun 2000 kuartal keempat. Keempat peubah tersebut adalah *e* (log *employ-*

ment), *prod* (log produktifitas buruh yang didefinisikan sebagai logaritma dari selisih antara GDP dan *employment*), *rw* (*real wage index* - upah sesungguhnya), dan *U* (*Unemployment* - pengangguran).

Langkah selanjutnya adalah melakukan uji kestasioneran data dengan *ADF-test*. *ADF-test* dibagi menjadi 2 bagian, yaitu tes dengan melibatkan kondisi musiman dan tes yang tidak melibatkan kondisi musiman. *ADF-test* untuk kondisi musiman menyatakan bahwa data Canada tidak mengandung kondisi musiman (*seasonal*). Pada versi ini pengujian *seasonalitas* hanya dilakukan untuk musim 3 (per kuartal), 6 (per setengah tahun), dan 12 (per tahun) saja. Namun, pengguna juga bisa mencoba untuk memasukkan data *seasonal* lain yang diduga. Hal ini akan diperbaiki untuk versi selanjutnya agar *package* dapat menjadi otomatis penuh. Peubah *e* dan *prod* menunjukkan kondisi tidak stasioner dengan *trend* dan *drift*, sedangkan peubah *rw* dan *U* menghasilkan keputusan bahwa kedua peubah tersebut stasioner. *ADF-test* yang langsung menguji kestasioneran dari peubah tanpa melihat apakah peubah mengandung musiman atau tidak menunjukkan bahwa keempat peubah tidak ada yang stasioner.

Analisis VAR

Data yang dimodelkan terlebih dahulu harus mengalami pemilihan *lag*, *stability check*, uji kenormalan model, dan identifikasi Granger-*causality*. *Lag* awal yang dipilih adalah 10 dan setelah mengalami serangkaian analisis, maka didapatkan *lag* terbaik adalah 3 dengan tipe *both*. Nilai *log-likelihood* model adalah -143,6292. Cek diagnostik untuk model dilakukan dengan histogram residual, uji normal untuk residual, plot ACF, dan plot PACF. Semua hasil menunjukkan bahwa model layak digunakan dalam meramalkan nilai masa mendatang.

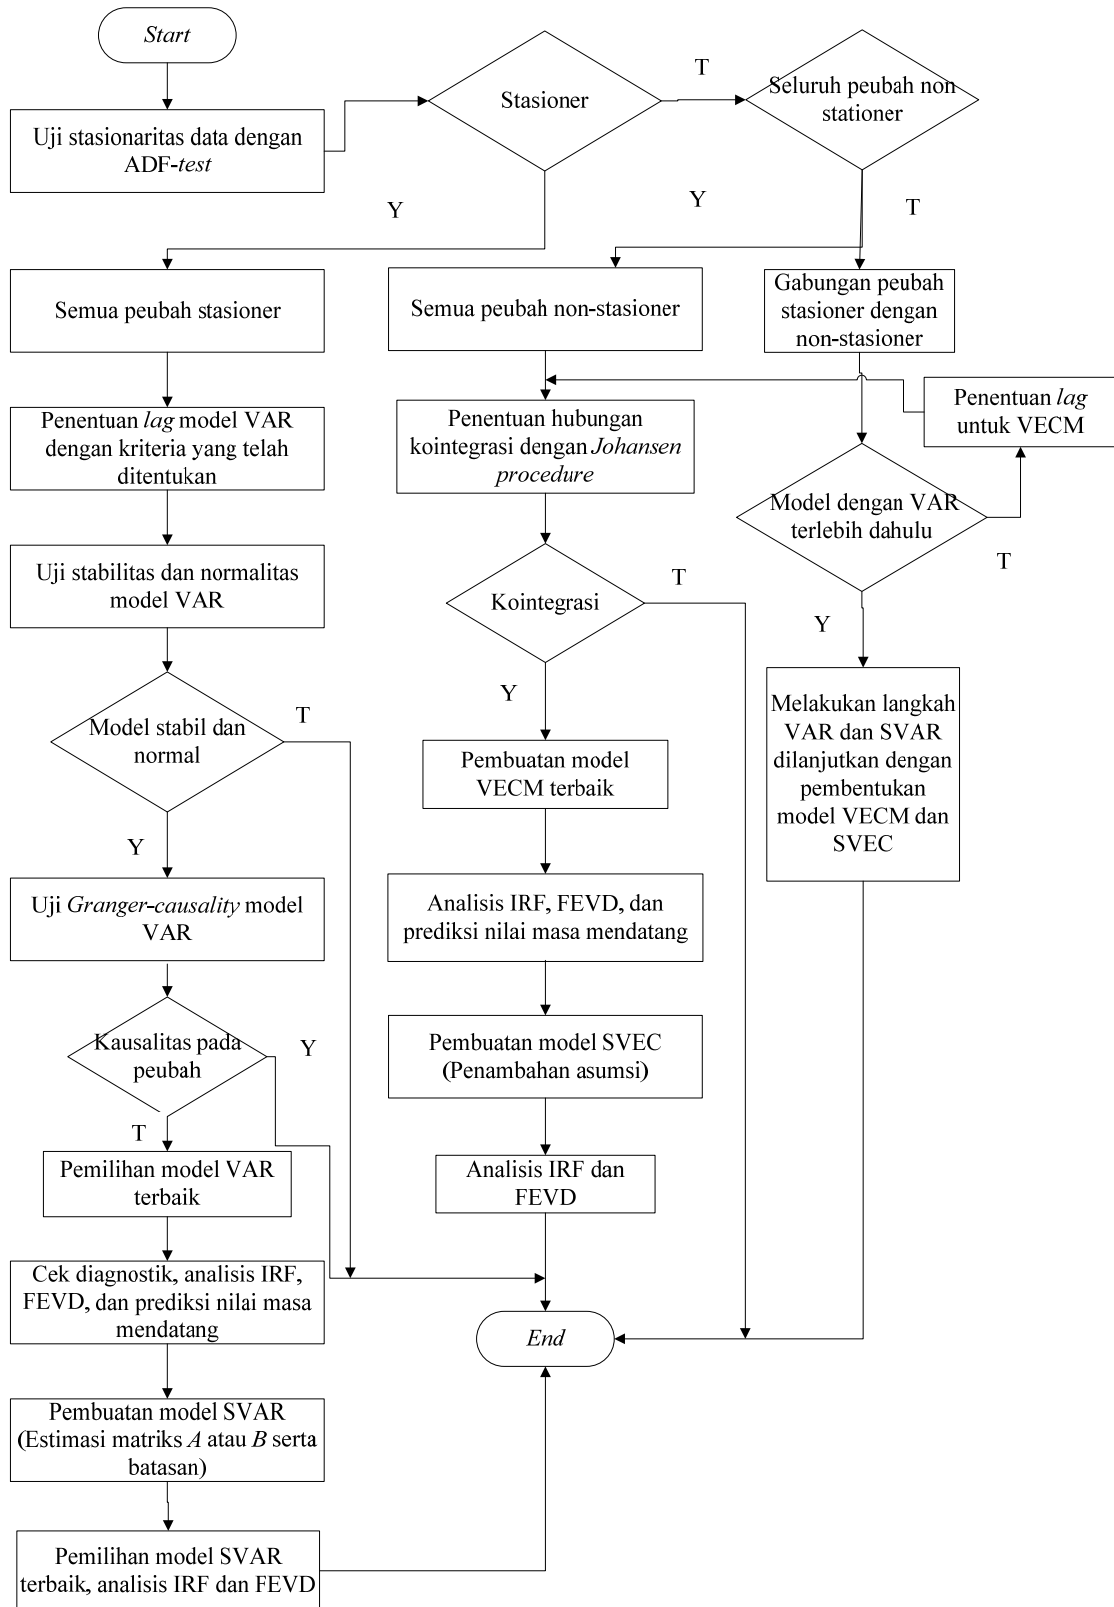
Hasil model VAR dapat dituliskan sebagai berikut:

$$\begin{bmatrix} e_t \\ prod_t \\ rw_t \\ U_t \end{bmatrix} = A_1 \begin{bmatrix} e_{t-1} \\ prod_{t-1} \\ rw_{t-1} \\ U_{t-1} \end{bmatrix} + A_2 \begin{bmatrix} e_{t-2} \\ prod_{t-2} \\ rw_{t-2} \\ U_{t-2} \end{bmatrix} + A_3 \begin{bmatrix} e_{t-3} \\ prod_{t-3} \\ rw_{t-3} \\ U_{t-3} \end{bmatrix} + \text{const} + \text{trend}$$

dimana

$$A_1 = \begin{bmatrix} 1,7638 & 0,1852 & -0,0724 & 0,1219 \\ -0,1962 & 1,0814 & -0,0200 & -0,7541 \\ -0,5247 & -0,1395 & 0,8603 & -0,1082 \\ -0,6306 & -0,1158 & 0,0027 & 0,6337 \end{bmatrix}$$

$$A_2 = \begin{bmatrix} -1,1901 & -0,1094 & -0,0249 & 0,0323 \\ -0,1548 & -0,1808 & -0,2012 & 0,7433 \\ 0,6967 & -0,1991 & 0,1433 & -0,3899 \\ 0,5254 & 0,0922 & 0,0705 & -0,1024 \end{bmatrix}$$



Gambar 1. *Flowchart* pembuatan model

$$A_3 = \begin{bmatrix} 0,6147 & 0,0256 & 0,0317 & 0,3598 \\ 0,4575 & -0,0205 & 0,1212 & 0,3222 \\ -0,2604 & 0,1416 & 0,2214 & 0,0626 \\ -0,0619 & -0,0285 & -0,0315 & 0,0455 \end{bmatrix}$$

$$const = \begin{bmatrix} -193,3704 \\ -13,2192 \\ 192,7772 \\ 163,8897 \end{bmatrix}, trend = \begin{bmatrix} -0,0174 \\ 0,0745 \\ 0,0834 \\ 0,0202 \end{bmatrix}$$


Gambar 2. Menunjukkan prediksi 5 pekan ke depan dari model VAR.

Analisis SVAR

Model SVAR yang dibuat adalah berdasarkan A model. Model SVAR membutuhkan batasan sehingga estimasi parameter dapat dilakukan. Empat batasan diberikan secara diagonal untuk matriks model SVAR dari data Canada. Pada versi ini batasan di atas ditanamkan dalam *package*. Hal ini dimaksudkan agar *running* program tidak berlebihan baik dalam waktu ataupun *space* untuk menyimpan setiap matrix yang harus dibangun di dalamnya. Tentunya diperlukan suatu algoritma yang tepat untuk mengatasinya. Masalah ini akan ditindaklanjuti pada penelitian selanjutnya. Dua peubah lainnya yang dijadikan batasan adalah peubah *e* untuk peubah *prod* dan peubah *e* untuk peubah *U*. Tabel 1. memberikan keterangan mengenai hasil dari estimasi model SVAR.

Analisis VECM

Ketidastasioneran pada data Canada membuat data tersebut harus dianalisis lebih lanjut menggunakan model VECM. *Lag* maksimum yang diberikan adalah 10 dan secara otomatis program akan mencari model dengan nilai *log-likelihood* maksimum. Model terbaik terdapat pada *lag* 10 dan tipe *both*. Hasil derajat kointegrasi dengan menggunakan *Johansen procedure* untuk model terbaik tersebut adalah berderajat 3. Diagnosis untuk model VECM adalah menggunakan histogram, Q-Q plot distribusi normal, ACF, dan PACF dari residual. Semua analisis telah memberikan kesimpulan bahwa model VECM ini layak digunakan untuk meramalkan nilai mendatang. Selanjutnya model VECM ini akan ditransformasikan menjadi model VAR, dan hasil yang diberikan adalah sebagai berikut:




Gambar 2. Peramalan model VAR lima periode

Tabel 1. Nilai *Log-Likelihood* dan Estimasi Matriks SVAR

Estimasi nilai matriks A model
 Nilai *log-likelihood*: -175.1474

Peubah	<i>e</i>	<i>prod</i>	<i>rw</i>	<i>U</i>
<i>E</i>	4,3390	0,2074	0	3,8300
<i>Prod</i>	0	1,5906	0	0
<i>Rw</i>	0	0	1,3580	0
<i>U</i>	0	0	0	3,5800



Gambar 3. Peramalan model VECM lima periode

$$\begin{bmatrix} e_t \\ prod_t \\ rw_t \\ U_t \end{bmatrix} = \sum_{i=1}^{10} A_i \begin{bmatrix} e_{t-i} \\ prod_{t-i} \\ rw_{t-i} \\ U_{t-i} \end{bmatrix} + const + trend$$

Sedangkan prediksi lima pekan mendatang ditunjukkan oleh Gambar 3.

Analisis SVEC

Peubah-peubah yang menjadi batasan *contemporaneous effect* adalah:

peubah *prod* → *U*, peubah *e* → *prod*, peubah *rw* → *U*, peubah *rw* → *prod*. Hasil dapat dilihat pada Tabel 2.

Peubah yang menjadi asumsi untuk *long-run effect* adalah peubah *rw* dan *U*. Hasil ini dapat dianalisis pada Tabel 3.

Tabel 2. Hasil SVEC untuk *contemporaneous impact*

Peubah	<i>e</i>	<i>prod</i>	<i>rw</i>	<i>U</i>
<i>e</i>	0,1813	0,0000	0,0870	-0,1125
<i>prod</i>	-0,0770	0,3449	0,0333	0,0000
<i>rw</i>	-0,4222	0,0000	0,2331	0,0000
<i>U</i>	-0,0725	-0,0103	0,0275	0,1630

Tabel 3. Hasil SVEC untuk *long-run impact*


Peubah	<i>e</i>	<i>prod</i>	<i>rw</i>	<i>U</i>
<i>e</i>	0,6971	-0,1498	0,0000	0,0000
<i>prod</i>	-0,2715	0,0584	0,0000	0,0000
<i>rw</i>	0,4368	-0,0939	0,0000	0,0000
<i>U</i>	-0,2287	0,0492	0,0000	0,0000

Analisis Impulse Response dan Variance Decomposition

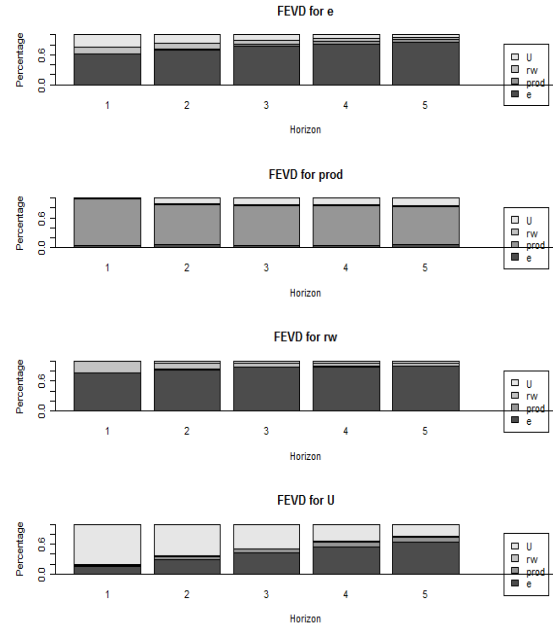
Analisis akan diberikan dari model SVEC. *Impulse response* dan *variance decomposition* secara berturut turut dapat dilihat pada Gambar 4 dan Gambar 5 Perubahan sebesar 1 standar deviasi pada peubah *prod* akan menyebabkan perubahan dengan tren negatif pada enam periode awal ditambah periode sekarang (periode 0). Setelah mengalami tren negatif selama beberapa periode, maka perubahan pada peubah *prod* akan menyebabkan peubah *U* mengalami kenaikan dari tren negatif menjadi positif Bermula pada periode ketujuh, kenaikan produktifitas sebaliknya menyebabkan kenaikan pada pengangguran. Jika dilihat secara visual, maka *impulse response* untuk *response* peubah *prod* terhadap peubah *U* masih dinilai cukup stabil. Hal ini dikarenakan rentang perubahan hanya di antara angka +/- 10% dan bergerak di garis tengah dari plot *impulse response*.

Pengaruh peubah *rw* tidak menunjukkan hasil yang cukup signifikan hingga periode kelima. Kontribusi yang diberikan oleh peubah *rw* relatif stabil dan hanya berkisar antara 1%-2,5%. Kontribusi peubah endogen lainnya yang cukup stabil juga ditunjukkan oleh peubah *e*. Perubahan yang dikarenakan oleh peubah *e* hanya sekitar 4%-6%. Meskipun pengaruh yang diberikan tidak terlalu besar, tetapi peubah *e* tidak boleh diabaikan.

Pergerakan untuk *shock* peubah *prod* memberikan kontribusi terbesar sepanjang periode. Pada periode kedua hingga kelima, nilai perubahan yang diberikan berada pada rentang 75%-80%. Adanya hasil sebesar itu yang berasal dari dirinya sendiri akan membuat kesulitan dalam menganalisis seberapa kuat hubungan *causality* dengan peubah lainnya. Hasil dari *variance decomposition* untuk menyatakan *causality* terkuat dapat dimiliki antara peubah *prod* dengan peubah *U*.



Gambar 4. Impulse response



Gambar 5. Variance Decomposition

Simpulan

Program *automatic multivariate* dengan *software R* telah mampu mengidentifikasi model terbaik untuk data *multivariate time series*. Model VAR yang digunakan untuk estimasi parameter pada data stasioner dan mencari *lag* serta tipe karakteristik sudah dapat membangun model secara baik. Model SVAR sebagai pelengkap analisis model VAR memiliki cakupan yang luas sehingga memungkinkan analisis melihat kombinasi struktural model berdasarkan kombinasi dan batasan di dalam matriks model.

Model VECM yang dikhususkan untuk data non-stasioner mampu mengestimasi derajat kointegrasi dengan *lag* dan tipe karakteristik yang tepat. Hasil tersebut akan menjadi unsur dalam transformasi model VECM menjadi model VAR. Analisis inovasi yang ditampilkan pada model SVEC dibuat dengan memperhatikan fleksibilitas dan kemudahan untuk pengguna. Hal ini memungkinkan pengguna untuk melihat hubungan antar peubah dengan asumsi yang dibuat oleh keputusan pengguna sendiri.

Nilai *log-likelihood* menjadi acuan dalam memilih model terbaik untuk semua model yang ada. Ketepatan dari model yang dipilih juga telah melalui serangkaian uji diagnostik. Prediksi nilai masa mendatang beserta analisis-*analisis* model dapat menghasilkan evaluasi dan solusi yang mendekati data riil. Namun masih terdapat beberapa hal, seperti batasan pada prediksi season yang hanya diberikan untuk musim 3,6 dan 12; serta batasan lain pada proses otomatisasi model SVAR. Keterbatasan ini akan diperbaiki pada *package* versi selanjutnya.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada para penelaah (*reviewer*) yang telah memberikan masukan hingga naskah ini menjadi lebih baik.

Daftar Pustaka

1. Akaike, H., Autoregressive model fitting for control, *Annals of the Institute of Statistical Mathematics*, 23, 1971, pp. 163-180.
2. Brooks, C., *Introductory econometrics for finance*. New York: Cambridge University Press, 2008.
3. Granger, C.W.J., Some Properties of Time Series Data and Their Use in Econometric Model Specification, *Journal of Econometrics*, 16, 1981, pp. 121-130.
4. Hadi, Y.S., Analisis Vector Autoregression (VAR) terhadap Korelasi antara Pendapatan Nasional dan Investasi Pemerintah di Indonesia. *Jurnal Keuangan dan Moneter*, 6, 2003, pp. 107-121.
5. Halim, S., Bisono, I.N., Melissa, and Cynthia, Automatic Seasonal Auto Regressive Moving Average Models and Unit Root Test Detection, *IEEE International conference on Industrial Engineering and Engineering Management proceeding*, Singapore 3-5 Dec, 2007, pp. 1129-1133.
6. Harris, R, and Sallis, R., *Applied time series modelling and forecasting*. New York: John Wiley & Sons, 2003.
7. Lütkepohl, H., *New introduction to multiple time series analysis*. Berlin: Springer, 2005
8. Pfaff, B., VAR, SVAR and SVEC models: Implementation within R package vars. *Journal of Statistical Software*, 27(4), 2008, pp. 1-29.
9. Sims, C. A., Macroeconomics and reality. *Journal Econometrica*, 48, 1980, pp. 1-48.