



ALGORITMA GENERALIZED REDUCED GRADIENT BERBASIS MARKOV-SWITCHING
MODEL UNTUK OPTIMISASI PORTOFOLIO SAHAM PERBANKAN DI INDONESIA

Oleh

Denny Nurdiansyah¹⁾ & Alif Yuanita Kartini³⁾

^{1,2}Universitas Nahdlatul Ulama Sunan Giri

Email: [1denny.nur@unugiri.ac.id](mailto:denny.nur@unugiri.ac.id) & [2alifyuanita@unugiri.ac.id](mailto:alifyuanita@unugiri.ac.id)

Abstrak

Optimisasi portofolio pada dasarnya menggunakan model Markowitz dalam menghasilkan portofolio yang efisien, namun portofolio yang terbentuk tidak baik ketika *return* saham memiliki perubahan *regime*, seperti pada periode 'bear' and 'bull' market. Tujuan dari penelitian ini adalah mengembangkan optimisasi portofolio dengan mempertimbangkan kasus perubahan *regime*, serta menerapkannya pada data runtun waktu yang memiliki perubahan *regime* dalam rangka pembentukan portofolio yang lebih efisien. Metode yang digunakan adalah algoritma *generalized reduced gradient* (GRG) berbasis *Markov-switching model* (MSwM). Pada penulisan ini akan dihasilkan algoritma pemrograman dalam *software* R untuk membuat paket program GRG berbasis MSwM yang akan digunakan untuk optimisasi portofolio pada kasus perubahan *regime*. Kinerja portofolio yang terbentuk dievaluasi dengan pengukuran risiko yaitu standar deviasi. Jenis data yang digunakan adalah data sekunder yang berisi saham-saham perbankan dari enam saham terpilih yang aktif di IDX Bursa Efek Indonesia pada tahun 2013-2018, yaitu: saham BRI, BNI, BTN, Bank Mandiri, BCA, dan Bank Danamon. Hasil diperoleh algoritma pemrograman untuk program GRG berbasis MSwM untuk optimisasi portofolio pada kasus perubahan *regime*, serta diperoleh portofolio saham perbankan yang optimal untuk tiga kriteria investor. Pada penelitian ini, portofolio terbaik jatuh pada kriteria investor yaitu meminimalkan risiko pada ekspektasi *return* tertentu. Penelitian ini memberikan kesimpulan bahwa algoritma GRG berbasis MSwM menghasilkan bobot portofolio berdasarkan fenomena "bull" and "bear" market, sehingga bobot portofolio yang terbentuk lebih realistis didalam pasar modal.

Kata Kunci: Portofolio Saham, Model Markowitz, Markov-Switching Model, Algoritma Generalized Reduced Gradient, Value-at-Risk.

PENDAHUALUAN

Berdasarkan Undang-Undang Nomor 8 Tahun 1995 tentang Pasar Modal (UUPM), pasar modal merupakan kegiatan yang bersangkutan dengan penawaran umum dan perdagangan efek (sekuritas) dari perusahaan publik yang berkaitan. Para pemodal (investor) menggunakan pasar modal untuk keperluan investasi portofolionya, sehingga pada akhirnya investor dapat memaksimalkan penghasilannya. Keuntungan atau kerugian yang diperoleh dari kegiatan investasi disebut sebagai *return*, sedangkan besar penyimpangan antara *return* aktual dan *return* yang diharapkan dalam investasi dapat disebut sebagai risiko. Portofolio merupakan kumpulan dari surat-surat berharga (sekuritas) yang berbeda seperti saham dan

obligasi yang mana dikombinasi dan dianggap sebagai aset tunggal (Booth dan Cleary, 2010). Teori keuangan menjelaskan bahwa risiko investasi meningkat sejalan dengan tingkat keuntungan yang diinginkan. Dengan menggabungkan beberapa sekuritas yang berbeda kedalam portofolio, investor berharap dapat meminimalkan kerugian atau risiko dalam berinvestasi.

Teori portofolio pertama kali diperkenalkan oleh Markowitz (1952) dengan merumuskan pengetahuan portofolio dalam model mean-varian Markowitz yang menggambarkan karakteristik risiko dan *return* dari portofolio keseluruhan, bukannya menyusun portofolio berdasarkan karakteristik risiko dan *return* yang menarik dari masing-masing individu sekuritas.



Penelitian terdahulu mengenai optimisasi portofolio telah dilakukan oleh Sartono dan Setiawan (2006), Yuniarti (2010), dan Ariany *et.al.* (2012). Dari ketiga penelitian ini, portofolio yang terbentuk tidak mempertimbangkan adanya kasus perubahan *regime*, sehingga portofolio yang terbentuk kurang realistis didalam pasar modal yang memiliki perubahan *regime*, yaitu periode “bull” and “bear” market. Selanjutnya pada penelitian Astuti (2006) tentang implementasi *Bayesian Markov Chain Monte Carlo* pada pemodelan portofolio optimal dengan pendekatan model *mixture* dari beberapa *mixture*, metode ini dapat diterapkan untuk kasus perubahan *regime* yang memiliki distribusi multimodal, namun bobot portofolio yang diestimasi hanya mempertimbangkan karakteristik risiko dan *return* dari masing-masing individu saham. Metode ini tidak mengikutsertakan karakteristik risiko dan *return* dari portofolio keseluruhan, sehingga portofolio yang terbentuk belum tentu efisien karena tidak ada ketentuan yang membandingkan portofolio yang diestimasi dengan portofolio lain yang memiliki kemungkinan sebagai portofolio yang efisien. Pada penelitian Sield (2012) tentang perbandingan metode Markowitz dan *regime switching* dengan pendekatan empiris. Kelebihan penelitian ini adalah portofolio yang terbentuk dengan metode *regime switching* merupakan portofolio yang optimal dengan mempertimbangkan karakteristik risiko dan *return* dari portofolio keseluruhan pada kasus perubahan *regime*. Pada peneliti ini, metode optimisasi yang digunakan adalah *gradient descent* yang mana metode ini tidak mempertimbangkan permasalahan komputasional *nonlinear programming*, yaitu adanya kekurangan perangkat model baik banyaknya variabel maupun banyaknya *constraints*, sehingga persamaan dalam banyak kasus tidak diperoleh eliminasi yang eksplisit. Untuk mengantisipasi kekurangan ini, digunakan algoritma *generalized reduced gradient* (GRG) yang diperkenalkan oleh Lasdon *et.al.* (1978) untuk menyelesaikan masalah *nonlinier programming*. Metode GRG ini menjadi *default*

metode untuk software *Excel's solver* yang biasanya digunakan untuk optimisasi portofolio (Beninga, 2008). Kelemahannya, metode ini hanya dapat digunakan pada kasus umum, serta tidak mempertimbangkan adanya kasus perubahan *regime*.

Dengan demikian, penulisan ini diusulkan algoritma *generalized reduced gradient* (GRG) berbasis *Markov-switching model* (MSwM) untuk optimisasi model mean-varian Markowitz pada kasus perubahan *regime*. MSwM pertama diperkenalkan oleh Hamilton (1989) untuk menyelesaikan *regime-switching model* (RSwM) dengan *return* aset yang berasumsi bahwa *regime* terjadi pada waktu t yang tidak teramati dan ditentukan oleh suatu proses yang tidak teramati yang mana disimbolkan dengan s_t (Franses dan Dijk, 2003). MSwM ini diterapkan pada model mean bersyarat yaitu model *autoregressive* (AR) yang dipopulerkan dalam buku Box dan Jenkins (1976). Estimasi Model digunakan metode *maximum likelihood* (ML) dan algoritma *expectation-maximization* (EM). Kinerja dari portofolio yang terbentuk dievaluasi dengan menggunakan *value-at-risk* (VaR). Dari algoritma GRG berbasis MSwM ini, dihasilkan bobot portofolio berdasarkan fenomena “bull” and “bear” market, sehingga bobot portofolio yang terbentuk lebih realistis didalam pasar modal. Oleh karena itu, dibutuhkan algoritma *generalized reduced gradient* (GRG) berbasis *Markov-switching model* (MSwM) untuk optimisasi portofolio saham perbankan di Indonesia.

LANDASAN TEORI

Teori Portofolio

Teori portofolio pertama kali diperkenalkan oleh Markowitz (1952) dengan tulisannya yang berjudul “*Portfolio Selection*”. Pada portofolio Markowitz, kriteria pemilihan portofolio yang digunakan adalah karakteristik *return* dan risiko dari portofolio keseluruhan, yaitu ekspektasi *return* portofolio dan standar deviasi portofolio. Misalkan R merupakan variabel random yang menyatakan suatu portofolio dengan $R \sim N(\mu_R, \sigma^2_R)$ dan r adalah variabel random yang menyatakan

<http://ejurnal.binawakya.or.id/index.php/MBI>



return aset dengan $r \sim N(\mu, \sigma^2)$. Rumusan untuk portofolio, ekspektasi return portofolio, dan standar deviasi portofolio masing-masing diberikan sebagai berikut:

1. portofolio

$$R_t = \sum_{a=1}^N w_a r_{a,t} ; \quad t = 1, 2, \dots, n \quad (1)$$

2. ekspektasi return portofolio

$$\mu_R = E[R_t] = \sum_{a=1}^N w_a \mu_a \quad (2)$$

3. standar deviasi portofolio

$$\sigma_R = \sqrt{\text{var}[R_t]} = \sqrt{\sum_{a=1}^N \sum_{b=1}^N w_a w_b \sigma_{ab}} \quad (3)$$

Konstanta N mewakili banyaknya sekuritas yang dimasukkan kedalam portofolio, sedangkan nilai n adalah banyaknya data pengamatan dari setiap sekuritas. Selanjutnya, perhitungan ini masing-masing dapat diberikan dalam bentuk matriks

$$R = r w = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1N} \\ r_{21} & r_{22} & \dots & r_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ r_{n1} & r_{n2} & \dots & r_{nN} \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_N \end{bmatrix}, \quad (4)$$

$$\mu^t = [\mu_1 \quad \mu_2 \quad \dots \quad \mu_N], \quad \mu_R = w^t \mu \quad (5)$$

dan

$$\Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N2} & \dots & \sigma_{NN} \end{bmatrix}, \quad \sigma_R^2 = w^t \Sigma \quad (6)$$

Pada penulisan ini, portofolio yang optimal diperoleh dari proses optimisasi portofolio pada tiga kriteria, yaitu:

1. meminimalkan standar deviasi portofolio pada ekspektasi return portofolio yang dikehendaki investor.
2. memaksimalkan ekspektasi return portofolio pada standar deviasi portofolio yang dikehendaki investor.
3. memaksimalkan *Sharpe Ratio* yang mengukur rasio dari ekspektasi return portofolio dan standar deviasi portofolio.

Algoritma Generalized Reduced Gradient

Algoritma *generalized reduced gradient* (GRG) merupakan pengembangan algoritma *reduced gradient* (RG) untuk menyelesaikan permasalahan umum *nonlinear programming*

(Lasdon *et.al.*, 1978). Algoritma GRG digunakan untuk menyelesaikan masalah *nonlinear programming* dengan bentuk umum

Meminimalkan $f(x)$

Batasan:

$$h_k(x) = 0 ; \quad k = 1, 2, \dots, K \quad (7)$$

dengan K adalah banyaknya persamaan pembatas (*constraints*) yang ditentukan.

Dengan memisalkan $x^{(r)}$ adalah titik layak pada iterasi ke- r dengan partisi $x = (\hat{x}, \bar{x})$, algoritma dasar GRG diberikan dalam Ravindran *et.al.* (2006) dengan prosedur sebagai berikut:

1. menghitung $\nabla \tilde{f}(x^{(r)}) = \nabla \tilde{f}(x^{(r)}) - \nabla \hat{f}(x^{(r)}) \cdot J^{-1}C$.
2. jika $\|\nabla \tilde{f}(x^{(r)})\| \leq \varepsilon_1$, maka proses iterasi berhenti; namun jika tidak terpenuhi, maka menghitung $\bar{d} = (-\nabla \tilde{f})^T$, $\hat{d} = -J^{-1}C \bar{d}$, dan $d = (\hat{d}, \bar{d})^T$.
3. meminimalkan $f(x^{(r)} + \alpha d)$ dengan mempertimbangkan parameter skalar α . Misalkan $\alpha^{(r)}$ menjadi α optimisasi, maka dilakukan penentuan persamaan $x^{(r+1)} = x^{(r)} + \alpha^{(r)} d$. Selanjutnya proses kembali ke tahap 1.

Pada tahap 3 dari prosedur algoritma GRG, dilakukan perhitungan secara iteratif dari persamaan

$$v^{(i)} = \bar{x}^{(r)} + \alpha \bar{d}, \quad i = 1, 2, \dots \quad (8)$$

dan berhenti untuk $|h_k(v^{(i)})| \leq \varepsilon_2$ dengan $\varepsilon_1, \varepsilon_2$ adalah nilai yang sangat kecil. Jika $f(x^{(r)}) \leq f(v^{(i)})$, maka $\alpha = \gamma \alpha$, $0 < \gamma < 1$ dan iterasi diulang; sedangkan jika syarat ini tidak terpenuhi, maka $x^{(r+1)} = v^{(i)}$. Agar batasan $h_k(x^{(r)}) = 0 ; \quad k = 1, 2, \dots, K$ tidak dilanggar pada penelitian ini, digunakan nilai awalan (*initial value*) dari bobot portofolio yang sama kemudian diberikan rangking berdasarkan perhitungan *Sharpe ratio* tanpa *return of risk-free asset*, kemudian bobot portofolio disesuaikan dengan penilaian ranking dan jumlahan bobot yang sama dengan satu.

Perluasan metode dasar diberikan untuk mengatasi keterbatasan algoritma GRG untuk *constraints* persamaan. Untuk *constraints* pertidaksamaan dalam Ravindran *et.al.* (2006),



diberikan bentuk pengembangan dengan bentuk umum

Meminimalkan $f(x)$

Batasan:

$$\begin{aligned}
 a_{k^*} &\leq g_{k^*}(x) \leq b_{k^*} \quad ; k^* = 1, 2, \dots, K^* \\
 h_k(x) &= 0 \quad ; k = 1, 2, \dots, K \quad (9) \\
 x_i^{(L)} &\leq x_i \leq x_i^{(U)} \quad ; i = 1, 2, \dots, M
 \end{aligned}$$

Jika *constraint* berbentuk pertidaksamaan $g_{k^*}(x) \leq b_{k^*}$, maka diberikan perlakuan

$$h_{k^*}(x) = g_{k^*}(x) - b_{k^*} + x_{M+k^*} = 0 \quad (10)$$

dengan x_{M+k^*} pada kondisi ini disebut sebagai variabel *slack* ke- k^* . Selanjutnya, jika *constraint* berbentuk pertidaksamaan $g_{k^*}(x) \geq a_{k^*}$, maka diberikan perlakuan

$$h_{k^*}(x) = g_{k^*}(x) - a_{k^*} - x_{M+k^*} = 0 \quad (11)$$

dengan x_{M+k^*} mewakili variabel *surplus* ke- k^* . Pada algoritma GRG, fungsi tujuan tidak terbatas untuk tujuan meminimalkan $f(x)$ karena meminimalkan $f(x)$ sama dengan memaksimalkan $-f(x)$, sehingga fungsi tujuan yang bertujuan memaksimalkan $f(x)$ dapat dirubah menjadi meminimalkan $-f(x)$. Hal ini juga berpengaruh pada nilai gradiennya, yaitu $\nabla f(x)$ berubah menjadi $-\nabla f(x)$. Untuk mengatasi variabel x yang melewati batas atas $x^{(U)}$ dan batas bawah $x^{(L)}$, dilakukan penentuan nilai x yang tetap berada didalam batasan tersebut.

Markov-Switching Model

Markov-switching model (MSwM) diperkenalkan oleh Hamilton (1989) untuk menyelesaikan *regime-switching model* dengan *return* aset yang berasumsi bahwa *regime* terjadi pada waktu t yang tidak teramati dan ditentukan oleh suatu proses yang tidak teramati yang mana disimbolkan dengan s_t (Franses dan Dijk, 2003). MSwM ini diterapkan pada model *conditional mean* yaitu model *Autoregressive* (AR) yang dipopulerkan dalam buku Box dan Jenkins (1976). Dalam kasus dua *regime*, s_t diasumsikan bernilai 1 dan 2, sehingga MSwM untuk model *Autoregressive* orde p [AR(p)] dalam dua *regime* diberikan rumusan sebagai

$$y_t =$$

$$\begin{cases}
 \varphi_{0,1} + \varphi_{1,1}y_{t-1} + \dots + \varphi_{p,1}y_{t-p} + \varepsilon_t & ; s_t = 1 \\
 \varphi_{0,2} + \varphi_{1,2}y_{t-1} + \dots + \varphi_{p,2}y_{t-p} + \varepsilon_t & ; s_t = 2
 \end{cases}
 , (12)$$

atau dapat diringkas penulisannya menjadi

$$\begin{aligned}
 y_t &= \varphi_{0,s_t} + \varphi_{1,s_t}y_{t-1} + \dots + \varphi_{p,s_t}y_{t-p} + \\
 &\varepsilon_t, \\
 \varepsilon_t &\sim N(0, \sigma_{s_t}^2). \quad (13)
 \end{aligned}$$

Proses s_t diasumsikan sebagai proses Markov orde pertama. Proses ini menjelaskan bahwa *regime* saat ini (s_t) tergantung pada *regime* satu periode sebelumnya (s_{t-1}), sehingga MSwM diperlengkap dengan mendefinisikan probabilitas transisi dari pergerakan dari satu *state* ke *state* yang lain sebagai berikut

$$\begin{aligned}
 P(s_t = 1 | s_{t-1} = 1) &= p_{11} \\
 P(s_t = 2 | s_{t-1} = 1) &= p_{12} \\
 P(s_t = 1 | s_{t-1} = 2) &= p_{21} \\
 P(s_t = 2 | s_{t-1} = 2) &= p_{22}.
 \end{aligned}
 \quad (14)$$

Dari empat probabilitas tersebut, didefinisikan bahwa p_{ij} adalah probabilitas *Markov Chain* yang bergerak dari *state* i pada waktu $t - 1$ menuju ke *state* j pada waktu t . Dengan kata lain, p_{ij} adalah probabilitas *regime* i pada waktu $t - 1$ diikuti oleh *regime* j pada waktu t . Probabilitas p_{ij} bernilai non-negatif dengan $p_{11} + p_{12} = 1$ dan $p_{21} + p_{22} = 1$. Dengan menggunakan teori *Ergodic Markov Chain* dalam Hamilton (1994), probabilitas tanpa bersyarat dapat diberikan sebagai

$$\begin{aligned}
 P(s_t = 1) &= \frac{1-p_{22}}{2-p_{11}-p_{22}} = \frac{p_{21}}{p_{12}-p_{21}} \\
 P(s_t = 2) &= \frac{1-p_{11}}{2-p_{11}-p_{22}} = \frac{p_{12}}{p_{12}-p_{21}}
 \end{aligned}
 \quad (15)$$

Estimasi *Markov-Switching Model* (MSwM) dengan metode *Maximum Likelihood* (ML) dan algoritma *Expectation-Maximization* (EM).

Dengan mempertimbangkan MSwM dua *regime* dan spesifikasi model AR(p) dalam kedua *regime*, MSwM dijabarkan sebagai

$$\begin{aligned}
 y_t &= \varphi_{0,s_t} + \varphi_{1,s_t}y_{t-1} + \dots + \varphi_{p,s_t}y_{t-p} + \\
 &\varepsilon_t \\
 \varepsilon_t &\sim N(0, \sigma_{s_t}^2)
 \end{aligned}
 \quad (16)$$

selanjutnya diberikan fungsi probabilitas densitas y_t dengan syarat *regime* s_t dan pengamatan historis $\Omega_{t-1} = \{y_{t-1}, y_{t-2}, \dots, y_1\}$ berdistribusi Normal dengan mean $\varphi_{0,s_t} +$



$\varphi_{1,st}y_{t-1} + \dots + \varphi_{p,st}y_{t-p}$ dan varian σ_{st}^2 dituliskan menjadi

$$f(y_t | s_t = j, \Omega_{t-1}; \theta) = \frac{\exp\left[-\frac{(y_t - \varphi_j' x_t)^2}{2\sigma_j^2}\right]}{\sigma_j \sqrt{2\pi}}, \quad (17)$$

keterangan:

$$\begin{aligned} x_t &= (1 \ y_{t-1} \ \dots \ y_{t-p})' \\ \varphi_j &= (\varphi_{0,j} \ \varphi_{1,j} \ \dots \ \varphi_{p,j})' \\ \theta &= (\varphi_1' \ \varphi_2' \ p_{11} \ p_{22} \ \sigma_1^2 \ \sigma_2^2)' \end{aligned}$$

Parameter θ merupakan suatu vektor yang berisi semua parameter dalam MSwM, kemudian fungsi probabilitas densitas $f(y_t | \Omega_{t-1}; \theta)$ dapat diperoleh dari densitas bersama dari y_t dan s_t mengikuti

$$\begin{aligned} f(y_t | \Omega_{t-1}; \theta) &= f(y_t, s_t = 1 | \Omega_{t-1}; \theta) + f(y_t, s_t = 2 | \Omega_{t-1}; \theta) \\ &= \sum_{j=1}^2 f(y_t | s_t = j, \Omega_{t-1}; \theta) \cdot P(s_t = j | \Omega_{t-1}; \theta). \end{aligned} \quad (18)$$

Penjabaran bentuk ini mengikuti aturan dasar dari probabilitas bersyarat yang mana probabilitas bersyarat dari dua kejadian A dan B yaitu $P(A \text{ dan } B)$ memiliki nilai sama dengan $P(A|B) P(B)$. Selanjutnya, fungsi *ln-likelihood* menjadi

$$\ln L(\theta | y_t, \Omega_{t-1}) = \sum_{t=1}^n \ln f(y_t | \Omega_{t-1}; \theta) \quad (19)$$

Untuk dapat menghitung probabilitas densitas (19), diperlukan probabilitas bersyarat dari *regime* berdasarkan informasi historis Ω_{t-1} , yaitu $P(s_t = j | \Omega_{t-1}; \theta)$. Jika *regime* terjadi pada waktu $t - 1$ diketahui dan termasuk dalam informasi himpunan Ω_{t-1} , maka prediksi dari probabilitas *regime* sama dengan probabilitas prediksi (probabilitas transisi dari proses Markov s_t) yang dijabarkan persamaannya sebagai

$$\hat{\xi}_{t|t-1} = P \cdot \xi_{t-1}. \quad (20)$$

keterangan:

$$\begin{aligned} \hat{\xi}_{t|t-1} &= (P(s_t = 1 | \Omega_{t-1}; \theta), P(s_t = 2 | \Omega_{t-1}; \theta))' \\ \xi_{t-1} &= \begin{cases} (1,0)' & ; s_{t-1} = 1 \\ (0,1)' & ; s_{t-1} = 2 \end{cases} \\ P &= \begin{pmatrix} p_{11} & 1 - p_{22} \\ 1 - p_{11} & p_{22} \end{pmatrix} \end{aligned}$$

Variabel $\hat{\xi}_{t|t-1}$ merupakan vektor 2 x 1 yang berisi probabilitas bersyarat dari *regime*,

sedangkan variabel P merupakan matriks yang berisi probabilitas transisi. Sebagaimana ditunjukkan dalam Hamilton (1990), estimasi *Maximum Likelihood* (ML) dari probabilitas transisi diberikan oleh

$$\hat{p}_{ij} = \frac{\sum_{t=2}^n P(s_t = j, s_{t-1} = i | \Omega_n; \hat{\theta})}{\sum_{t=2}^n P(s_{t-1} = i | \Omega_n; \hat{\theta})} \quad (21)$$

Dalam penulisan ini, probabilitas *regime* yang digunakan untuk membagi data pengamatan berdasarkan *regime* adalah probabilitas *filtering* yang mana dirumuskan perhitungannya dalam Seidl (2012) sebagai

$$\begin{aligned} \hat{\xi}_{t|t} &= P(s_t = j | \Omega_t; \theta) \\ &= \frac{P(s_t = j | \Omega_{t-1}; \theta) f(y_t | s_t = j, \Omega_{t-1}; \theta)}{f(y_t | \Omega_{t-1}; \theta)}. \end{aligned} \quad (22)$$

Probabilitas *filtering* adalah probabilitas *regime* yang diberikan jika *regime* terjadi pada waktu t diketahui dan termasuk dalam informasi himpunan Ω_t .

Algoritma Alokasi Portofolio Berdasarkan Regime

Pada penulisan ini, digunakan algoritma alokasi portofolio berdasarkan *regime* yang dikembangkan dari algoritma Seidl (2012) dengan langkah-langkah berikut:

1. mengestimasi parameter θ pada persamaan *regime* (13) dari *return* portofolio yang terbentuk pada bobot portofolio yang sama.
2. mendapatkan probabilitas transisi (P) pada persamaan (21) dan probabilitas *filtering* ($\hat{\xi}_{t|t}$) pada persamaan (22).
3. membagi sampel pengamatan menjadi dua periode *regime* berdasarkan probabilitas *filtering* ($\hat{\xi}_{t|t}$), yaitu periode *regime* 1 dan periode *regime* 2.
4. menghitung matriks korelasi antara sekuritas pada periode *regime* 1 dan periode *regime* 2.
5. mengestimasi nilai ekspektasi *return* aset (μ_{s_t}) dan varian-kovarian asset (Σ_{s_t}), serta mendapatkan bobot portofolio (w_{s_t}) untuk setiap sekuritas yang dependen terhadap *regime*. Bobot portofolio ini diperoleh dari hasil optimisasi portofolio, sehingga dihasilkan juga ekspektasi *return* portofolio (μ_{R,s_t}) dan standar deviasi portofolio (σ_{R,s_t}). Berikut diberikan rumusan μ_{s_t} , Σ_{s_t} , μ_{R,s_t} ,



dan σ_{R,s_t} masing-masing

$$\mu_{s_t} = \frac{1}{n_{s_t}} \sum_{i=1}^{n_{s_t}} r_i, \quad (23)$$

$$\Sigma_{s_t} = (\text{cov}(r_i, r_j))_{i,j=1,2,\dots,n_{s_t}}, \quad (24)$$

$$\mu_{R,s_t} = \sum_{a=1}^N w_{s_t,a} \mu_{s_t,a}, \quad (25)$$

dan

$$\sigma_{R,s_t} = \sqrt{\sum_{a=1}^N \sum_{b=1}^N w_{s_t,a} w_{s_t,b} \sigma_{s_t,ab}}. \quad (26)$$

6. menghitung *unconditioned portfolio weights* (*upw*) untuk setiap sekuritas. Pada penulisan ini diusulkan penggabungan bobot dengan rumusan

$$upw = p_1^* w_1 + p_2^* w_2 \quad (27)$$

dengan $p_1^* = P(s_t = 1)$ dan $p_2^* = P(s_t = 2)$ masing-masing adalah probabilitas tanpa syarat yang dijabarkan pada persamaan (15), serta w_i adalah bobot portofolio optimal pada *regime* ke- i dengan $i = 1, 2$.

7. menghitung nilai ekspektasi *return* portofolio (μ_R) dan standar deviasi portofolio (σ_R) berdasarkan *upw*.

METODOLOGI PENELITIAN

Sumber Data

Data yang akan digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari PT. TICMI yang mana merupakan anak perusahaan Bursa Efek Jakarta. Data yang digunakan adalah data runtun waktu harian *close price* untuk menghitung *return* mingguan saham-saham perbankan di IDX Bursa Efek Indonesia pada tanggal 4 Januari 2013 sampai 28 Desember 2018

Variabel Penelitian

Pada penelitian ini, digunakan variabel-variabel penelitian yaitu *close price* dari saham-saham terpilih yang aktif di Bursa Efek Indonesia tahun 2014-2018, yaitu: saham BRI, saham BNI, saham BTN, saham Bank Mandiri, saham BCA, dan saham Bank Danamon. Adapun variabel-variabel yang digunakan sebagai berikut:

Tabel 1. Variabel Penelitian Saham Perbankan di Indonesia

No.	Nama Variabel	Simbol
1	<i>close price</i> BBRI	P_{BBRI}
2	<i>close price</i> BBNI	P_{BBNI}
3	<i>close price</i> BBTN	P_{BBTN}
4	<i>close price</i> BMRI	P_{BMRI}
5	<i>close price</i> BBKA	P_{BBKA}
6	<i>close price</i> BDMN	P_{BDMN}

Close price merupakan harga penutupan saham yang diperdagangkan pada hari *trading*. *Return* saham dalam Beninga (2008) dihitung dengan rumusan *continuously compounded return*, yaitu,

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right); t = 1, 2, \dots, n \quad (32)$$

dengan n adalah banyaknya pengamatan dan P_t adalah *close price* pada waktu t .

Langkah Penelitian

Langkah-langkah algoritma GRG dengan MSwM *based* diberikan sebagai berikut:

1. menginputkan data *close price* seluruh sekuritas.
2. menghitung *return* setiap sekuritas.
3. menghitung *return* portofolio yang terbentuk pada bobot portofolio yang sama.
4. mengestimasi parameter *Markov-Switching Model* dari *return* portofolio yang terbentuk dengan menggunakan paket program R, yaitu paket MSwM. Paket program ini dibuat untuk mengestimasi *Markov-Switching Model* dengan menggunakan metode *Maximum Likelihood* (ML) dan algoritma *Expectation-Maximization* (EM).
5. menentukan *regime* semua *return* sekuritas berdasarkan probabilitas *filtering* ($\hat{\xi}_{t|t}$) yang diestimasi pada langkah 4.
6. membagi semua *return* sekuritas menjadi dua periode berdasarkan probabilitas *filtering* ($\hat{\xi}_{t|t}$), yaitu periode *regime* 1 dan periode *regime* 2.
7. menghitung matriks korelasi antara *return* sekuritas pada *regime* 1 dan *regime* 2.
8. menghitung matriks ekspektasi *return* dan



- matriks varian-kovarian dari sekuritas keseluruhan pada *regime* 1 dan *regime* 2.
9. mengidentifikasi kelayakan *regime* sebagai periode 'bear' and 'bull' market untuk diterapkan ke semua *return* saham dalam portofolio berdasarkan output korelasi, ekspektasi *return* saham, dan standar deviasi saham.
 10. menampilkan bobot portofolio (w_{s_t}) untuk setiap *regime* dengan optimisasi portofolio yang diberikan dalam program *Generalized Reduced Gradient* (GRG) secara umum dengan langkah berikut:
 - 10.1. menentukan nilai awal (*initial value*) untuk bobot portofolio (w).
 - 10.2. mendefinisikan fungsi tujuan $f(w)$ dan fungsi pembatas $h(w)$ beserta gradien fungsinya, yaitu $\nabla f(w)$ dan $\nabla h(w)$. Fungsi-fungsi ini tergantung kriteria investor yang dipertimbangkan.
 - 10.3. menghitung gradien $\nabla f(w^{(r)})$ dan $\nabla h(w^{(r)})$ tergantung kriteria investor yang dipertimbangkan; selanjutnya menentukan partisi $w = (\hat{w}, \bar{w})$, serta matriks J dan C .
 - 10.4. menghitung gradien $\nabla \tilde{f}(w^{(r)}) = \nabla \tilde{f}(w^{(r)}) - \nabla \tilde{f}(w^{(r)}) \cdot J^{-1}C$. Jika $\|\nabla \tilde{f}(w^{(r)})\| \leq \epsilon_1$, maka proses iterasi berhenti; namun jika tidak terpenuhi, maka menghitung $\bar{d} = (-\nabla \tilde{f})^T$, $\hat{d} = -J^{-1}C \bar{d}$, dan $d = (\hat{d}, \bar{d})^T$.
 - 10.5. meminimalkan $f(w^{(r)} + \alpha d)$ dengan mempertimbangkan parameter skalar α . Misalkan $\alpha^{(r)}$ menjadi α optimisasi, maka dilakukan penentuan persamaan $w^{(r+1)} = w^{(r)} + \alpha^{(r)}d$. Selanjutnya proses kembali ke langkah 10.3.
 11. menampilkan bobot portofolio (w_{s_t}) untuk setiap *regime*.
 12. menghitung *unconditioned portfolio weights* (upw).
 13. menghitung nilai ekspektasi *return* portofolio (μ_R) dan standar deviasi portofolio (σ_R) berdasarkan upw untuk gambaran karakteristik portofolio yang terbentuk.

14. menampilkan *unconditioned portfolio weights* (upw), ekspektasi *return* portofolio (μ_R) dan standar deviasi portofolio (σ_R).

HASIL DAN PEMBAHASAN

Pada pembahasan ini, diberikan optimisasi portofolio dilakukan untuk menyelesaikan model *programming* dari tiga kriteria berikut:

1. meminimalkan standar deviasi portofolio pada ekspektasi *return* portofolio yang dikehendaki investor, yaitu

Meminimalkan $f(w) = \sigma_R = \sqrt{\sum_{a=1}^N \sum_{b=1}^N w_a w_b \sigma_{ab}}$
Batasan:

$$\begin{aligned} \mu_R &= \sum_{a=1}^N w_a \mu_a \geq \mu_0 \\ \sum_{a=1}^N w_a &= 1 \\ w_a &\geq 0 ; a = 1, 2, \dots, N \end{aligned} \quad (33)$$

2. memaksimalkan ekspektasi *return* portofolio pada standar deviasi portofolio yang dikehendaki investor, yaitu

Memaksimalkan $f(w) = \mu_R = \sum_{a=1}^N w_a \mu_a$
Batasan:

$$\begin{aligned} \sigma_R &= \sqrt{\sum_{a=1}^N \sum_{b=1}^N w_a w_b \sigma_{ab}} \leq \sigma_0 \\ \sum_{a=1}^N w_a &= 1 \\ w_a &\geq 0 ; a = 1, 2, \dots, N \end{aligned} \quad (34)$$

3. memaksimalkan *Sharpe Ratio* yang mengukur rasio dari ekspektasi *return* portofolio dan standar deviasi portofolio, yaitu

Memaksimalkan

$$f(w) = \Phi = \frac{\mu_R}{\sigma_R} = \frac{\sum_{a=1}^N w_a \mu_a}{\sqrt{\sum_{a=1}^N \sum_{b=1}^N w_a w_b \sigma_{ab}}}$$

Batasan:


$$\begin{aligned} \sum_{a=1}^N w_a &= 1 \\ w_a &\geq 0 ; a = 1, 2, \dots, N \end{aligned} \quad (35)$$

Pada penulisan ini, sumber data yang diperoleh adalah data sekunder yang berisi data harian close price dari saham-saham perbankan dari enam saham terpilih yang aktif di IDX Bursa Efek Indonesia pada tahun 2013-2018, yaitu: saham BRI, BNI, BTN, Bank Mandiri, BCA, dan Bank



Danamon. Data harian close price ini dibeli dari PT. TICMI yang mana merupakan anak perusahaan Bursa Efek Jakarta. Data harian close price digunakan untuk menghitung return harian saham-saham tersebut pada tanggal 4 Januari 2013 sampai 28 Desember 2018. Pada proses seleksi portofolio, sebelum saham-saham dimasukkan kedalam portofolio, saham-saham yang dipilih harus lulus identifikasi pengamatan historis peneliti. Misalkan pada penelitian ini saham-saham yang dipilih berasal dari sektor yang sama, memiliki *close price* yang tinggi, dan memiliki pergerakan data historis yang menunjukkan trend naik. Ketentuan ini menghasilkan pilihan untuk meneliti saham-saham dari sektor perbankan Indonesia, yaitu BBRI, BBNI, BBTN, BMRI, BBKA, dan BDMN. Berikut diberikan plot runtun waktu dari *close price* saham yang memiliki pergerakan data historis yang menunjukkan trend naik.

Gambar 1. Plot Runtun Waktu dari Close Price Saham BBRI, BBNI, BBTN, BMRI, BBKA, dan BDMN.

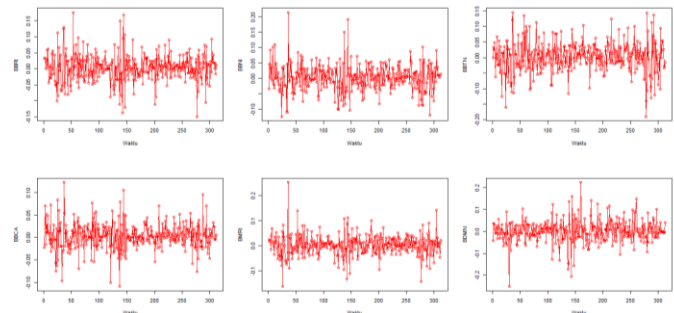


Pada trend naik, investor akan memiliki kepercayaan yang tinggi mengenai keuntungan berlebih pada investasi di masa depan (*capital gains*). Dari Gambar 1, terlihat bahwa *close price* yang memiliki pergerakan data historis yang menunjukkan trend naik meskipun kurun waktu akhir-akhir ini menunjukkan tren turun. Dari pergerakan semua *close price* saham, terlihat adanya fenomena periode “bull” and “bear” market yang ditunjukkan oleh adanya kenaikan dan penurunan dari semua *close price* saham pada periode tertentu. Pada minggu terakhir (tanggal 3 Agustus 2018), diperoleh *close price* mingguan pada enam saham perbankan yang terpilih, yaitu BBRI sebesar 3330, BBNI sebesar 7900, BBTN sebesar 2450, BMRI sebesar 7200, Vol.14 No.2 September 2019

BBKA sebesar 23450, dan BDMN sebesar 6650.

Data *close price* saham digunakan untuk menghitung *return* saham dengan rumusan $r_t = \ln(P_t/P_{t-1})$ dengan $t = 1, 2, \dots, n$. Diberikan plot runtun waktu dan Statistika deskriptif sebagai berikut.

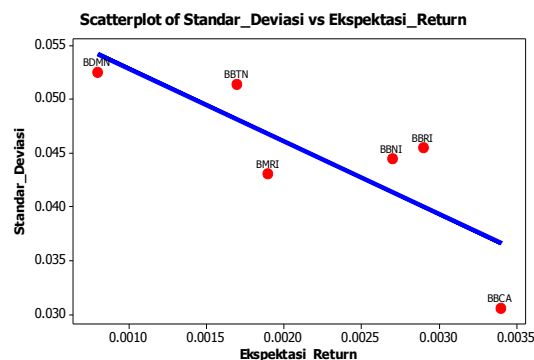
Gambar 2. Plot Runtun Waktu dari Return Saham BBRI, BBNI, BBTN, BMRI, BBKA, dan BDMN.



Tabel 2. Statistika Deskriptif dari Return Saham Perbankan di Indonesia.

Saham	N	Ekspektasi Return	Standar Deviasi
BBRI	312	0,29%	0,0454
BBNI	312	0,27%	0,0444
BBTN	312	0,17%	0,0513
BBKA	312	0,34%	0,0305
BMRI	312	0,19%	0,0430
BDMN	312	0,08%	0,0524

Gambar 3. Diagram Pencar dengan Regresi dari Close Price Saham BBRI, BBNI, BBTN, BMRI, BBKA, dan BDMN



Dari output Tabel 2 dan Gambar 3, ekspektasi return tertinggi diberikan oleh saham



BBCA sebesar 0.34% dengan risiko (standar deviasi) sebesar 0,0305 dan ekspektasi return terendah ditunjukkan oleh saham BBDM sebesar 0,08% dengan risiko (standar deviasi) sebesar 0,0524. Risiko tertinggi diberikan oleh BDMN, sedangkan risiko terendah justru diberikan oleh saham BBCA. Dari hasil ini, karakteristik enam saham ini tidak sesuai dengan teori ekonomi yang berbunyi bahwa keuntungan meningkat sejalan dengan risikonya. Teori ini juga tidak berlaku pada fenomena periode “bull” and “bear” market. Namun, ukuran statistik pada Tabel 2 bersifat umum yang mana tidak menunjukkan ukuran statistik pada fenomena periode “bull” and “bear” market.

Penerapan Studi Kasus berdasarkan MSwM-AR(1).

Identifikasi kelayakan *regime* sebagai periode ‘bear’ and ‘bull’ market untuk semua *return* saham dilakukan berdasarkan output korelasi antar *return* saham, serta output dari ekspektasi *return* dan standar deviasi pada setiap *return* saham. Ketika *regime* pada *return* portofolio (dengan bobot yang sama) diterapkan pada semua *return* saham, periode ‘bull’ market akan ditunjukkan dengan korelasi antara *return* saham lebih rendah, ekspektasi *return* setiap *return* saham lebih tinggi, dan standar deviasi setiap *return* saham lebih rendah; sedangkan periode ‘bear’ market akan ditunjukkan dengan korelasi antara *return* saham lebih tinggi, ekspektasi *return* setiap *return* saham lebih rendah, dan standar deviasi setiap *return* saham lebih tinggi (Sield, 2012).

Diberikan output korelasi semua saham didalam portofolio, sebagai berikut:

Tabel 3. Korelasi antara Return Saham berdasarkan Regime MSwM-AR(1).

No	Saham (i)	Saham (j)	Korelasi Regime 1	Korelasi Regime 2
1	BBRI	BBNI	0.4270*	0.7406*
2	BBRI	BBTN	0.1681	0.5549*
3	BBNI	BBTN	0.3257*	0.6809*
4	BBRI	BBCA	0.1243	0.7509*

No	Saham (i)	Saham (j)	Korelasi Regime 1	Korelasi Regime 2
5	BBNI	BBCA	0.4227*	0.7478*
6	BBTN	BBCA	0.2575*	0.6470*
7	BBRI	BMRI	0.6607*	0.8687*
8	BBNI	BMRI	0.4653*	0.7615*
9	BBTN	BMRI	0.1788*	0.6067*
10	BBCA	BMRI	0.1880*	0.7307*
11	BBRI	BDMN	0.1659	0.4449*
12	BBNI	BDMN	0.2698*	0.5124*
13	BBTN	BDMN	0.1882*	0.3329*
14	BBCA	BDMN	0.1648	0.5040*
15	BMRI	BDMN	0.1721*	0.4034*

*Korelasi signifikan untuk α sebesar 5% (P -value < 5%).

Dari output Tabel 3, diperoleh semua korelasi pada regime 2 lebih tinggi daripada korelasi pada regime 1. Hasil ini menunjukkan bahwa regime 1 memiliki kecenderungan sebagai periode “bull” market dan regime 2 memiliki kecenderungan sebagai periode “bear” market. Untuk memastikan kesimpulan ini, dilakukan pemeriksaan pada statistika deskriptif khususnya ekspektasi return dan standar deviasi dari setiap return saham pada regime 1 ($n_1 = 227$) dan regime 2 ($n_2 = 85$).

Tabel 4. Statistika Deskriptif Return Saham berdasarkan Regime MSwM-AR(1).


Saham	Ekspektasi Return Regime 1	Ekspektasi Return Regime 2	Standar Deviasi Regime 1	Standar Deviasi Regime 2
BBRI	0.56%	-0.42%	0.0327	0.0683
BBNI	0.54%	-0.45%	0.0327	0.0661
BBTN	0.46%	-0.62%	0.0418	0.0706
BBCA	0.49%	-0.07%	0.0228	0.0450
BMRI	0.45%	-0.51%	0.0304	0.0656
BDMN	0.47%	-0.97%	0.0451	0.0672

Dari output statistika deskriptif, semua return saham memiliki ekspektasi return lebih tinggi pada regime 1 daripada regime 2, serta semua standar deviasi dihasilkan lebih rendah pada regime 1 daripada regime 2. Dari hasil pemeriksaan korelasi dan statistika deskriptif dapat disimpulkan bahwa regime 1 merupakan




periode “bull” market dan regime 2 merupakan periode “bear” market yang mana digambarkan berikut.


Gambar 4. Plot Runtun Waktu dari Return Portofolio dengan Area Gelap sebagai Regime 1 (periode “bull” market) berdasarkan MSwM-AR(1).



Gambar 5. Diagram Pencar dengan Regresi pada regime 1 dari Close Price Saham BBRI, BBNI, BBTN, BBKA, BMRI, dan BDMN.



Gambar 6. Diagram Pencar dengan Regresi pada regime 2 dari Close Price Saham BBRI, BBNI, BBTN, BBKA, BMRI, dan BDMN.



Pada periode “bear” market (regime 1), ekspektasi return tertinggi diberikan oleh saham BBRI sebesar 0.56% dengan risiko (standar deviasi) sebesar 0.0327, dan ekspektasi return

terendah ditunjukkan oleh saham BMRI sebesar 0.45% dengan risiko sebesar 0,0304. Disisi lain pada periode “bull” market (regime 2), ekspektasi return tertinggi diberikan oleh saham BBKA sebesar -0,07% dengan risiko sebesar 0,0450, dan ekspektasi return terendah ditunjukkan oleh saham BDMN sebesar -0,97% dengan risiko sebesar 0,0672. Risiko tertinggi diberikan oleh saham BDMN dan risiko terendah ditunjukkan oleh saham BBKA pada periode “bear” and “bull” market.

Dengan demikian, algoritma GRG dengan MSwM based dapat diterapkan untuk optimisasi portofolio. Penerapan metode ini diberikan dengan mempertimbangkan tiga kriteria investor. Optimisasi portofolio pertama dilakukan untuk kriteria bagaimana meminimalkan standar deviasi portofolio pada ekspektasi return portofolio yang dikehendaki investor. Nilai pada regime 1 dihitung dengan rata-rata dari semua ekspektasi return regime 1 pada Tabel 4, sedangkan output saran pada regime 2 diperoleh dari perhitungan rata-rata dari semua ekspektasi return regime 2 pada Tabel 4. Dengan demikian, user dapat menggunakan nilai μ_0 regime 1 sebesar 0,0049 (0,49%) dan nilai μ_0 regime 2 sebesar 0 (0%), sehingga diperoleh output bobot portofolio regime 1, bobot portofolio regime 2, dan unconditioned portfolio weights (upw) pada tabel berikut.

Tabel 5. Bobot Portofolio berdasarkan Metode GRG dengan MSwM-AR(1) based pada Kriteria Pertama.

Saham	Bobot Portofolio Regime 1	Bobot Portofolio Regime 2	Bobot Portofolio (upw)
BBRI	18,65%	30%	26,70%
BBNI	0%	20%	14,19%
BBTN	6,47%	0%	1,88%
BBKA	51,21%	40%	43,25%
BMRI	14,66%	10%	11,35%
BDMN	9,01%	0%	2,62%
Ekspektasi Return	0,49%	-0,29%	0,29%
Standar Deviasi	0,0187	0,0530	0,0319

Pada Tabel 5, dihasilkan return portofolio dengan



ekspektasi return portfolio sebesar 0,29% dan standar deviasi portfolio sebesar 0,0319. Hasil perolehan ini memberikan nilai ekspektasi return dan risiko yang lebih realistik pada periode “bear” and “bull” market. Hasil ini menunjukkan risiko yang lebih rendah dengan keuntungan yang dapat diterima. Nilai ini digunakan sebagai gambaran karakteristik dari portofolio yang terbentuk.

Optimisasi portofolio kedua diberikan untuk kriteria bagaimana memaksimalkan ekspektasi return portofolio pada standar deviasi portofolio yang dikehendaki investor. Nilai σ_0 pada *regime* 1 dihitung dengan nilai minimal dari semua standar deviasi *regime* 1 pada Tabel 4, sedangkan output saran σ_0 pada *regime* 2 dihasilkan dari perhitungan nilai minimal dari semua standar deviasi *regime* 2 pada Tabel 4. Dengan demikian, *user* dapat menggunakan nilai σ_0 untuk *regime* 1 dan *regime* 2 masing-masing bernilai 0,0228 dan 0,045, sehingga diperoleh output bobot portofolio *regime* 1, bobot portofolio *regime* 2, dan *unconditioned portfolio weights (upw)* sebagai berikut.

Tabel 6. Bobot Portofolio berdasarkan Metode GRG dengan MSwM-AR(1) based pada Kriteria Kedua.

Saham	Bobot Portofolio Regime 1	Bobot Portofolio Regime 2	Bobot Portofolio (upw)
BBRI	100%	50.01%	64,53%
BBNI	0%	0%	0%
BBTN	0%	0%	0%
BBCA	0%	40.02%	28.40%
BMRI	0%	10.00%	7,09%
BDMN	0%	0%	0%
Ekspektasi Return	0,56%	-0,29%	0,30%
Standar Deviasi	0,0327	0,0549	0,0370

Pada Tabel 6, dihasilkan return portofolio dengan ekspektasi return portofolio sebesar 0,30% dan standar deviasi portofolio sebesar 0,0370. Hasil perolehan ini memberikan nilai ekspektasi return dan risiko yang lebih realistik pada periode “bear” and “bull” market. Hasil ini menunjukkan keuntungan yang lebih tinggi dengan risiko yang

dapat diterima. Hasil standart deviasi ini tidak lebih baik dari hasil portofolio yang pertama terbentuk.

Optimisasi portofolio ketiga digunakan untuk kriteria bagaimana memaksimalkan *Sharpe Ratio* yang mengukur rasio dari ekspektasi return portofolio dan standar deviasi portofolio, sehingga dihasilkan output bobot portofolio *regime* 1, bobot portofolio *regime* 2, dan *unconditioned portfolio weights (upw)* sebagai berikut.

Tabel 7. Bobot Portofolio berdasarkan Metode GRG dengan MSwM-AR(1) based pada Kriteria Ketiga.

Saham	Bobot Portofolio Regime 1	Bobot Portofolio Regime 2	Bobot Portofolio (upw)
BBRI	26,06%	51.74%	44,28%
BBNI	1,71%	14.44%	10.74%
BBTN	5.23%	0%	1.52%
BBCA	55.59%	33.82%	6,86%
BMRI	4.29%	0%	9,14%
BDMN	7.11%	0%	0%
Ekspektasi Return	0.50%	-0.30%	0,30%
Standar Deviasi	0.0189	0.0556	0,0332


Pada Tabel 7, dihasilkan return portofolio dengan ekspektasi return portofolio sebesar 0,30% dan standar deviasi portofolio sebesar 0,0332. Hasil perolehan ini memberikan nilai ekspektasi return dan risiko yang lebih realistik pada periode “bear” and “bull” market. Hasil ini menunjukkan keuntungan yang lebih tinggi dibarengi risiko yang terjaga. Hasil ini juga standart deviasi ini tidak lebih baik dari hasil portofolio yang pertama terbentuk.

Penerapan Studi Kasus berdasarkan MSwM-AR(2).

Sama halnya dengan kasus MSwM-AR(1), diberikan perlakuan yang sama pada kasus MSwM-AR(2) yang mana menghasilkan kesimpulan *regime* yang sama bahwa *regime* 1 merupakan periode “bull” market dan *regime* 2 merupakan periode “bear” market yang mana digambarkan berikut.



Gambar 7. Plot Runtun Waktu dari Return Portofolio dengan Area Gelap sebagai Regime 1 (periode "bull" market) berdasarkan MSwM-AR(2).



Tabel 8. Ringkasan Hasil Optimisasi Portofolio pada Kasus MSwM-AR(2).

Kriteria Investor		I	II	III
Bobot Portofolio (upw)	BBRI	26.69%	16.52%	39.89%
	BBNI	14.21%	35.58%	12,54%
	BBTN	1.95%	0%	1.56%
	BBCA	43,10%	37.98%	41.57%
	BMRI	11,24%	9,99%	2,47%
	BDMN	2,80%	0%	1.97%
Ekspektasi Return		0.29%	0,29%	0,30%
Standar Deviasi		0.0318	0,0334	0,0327

Saham-saham yang terseleksi pada proses ini ditunjukkan dari perolehan bobot portofolionya. Nilai standar deviasi terbaik ditunjukkan oleh metode GRG berbasis MSwM-AR(2) yang memiliki risiko terendah dengan keuntungan lebih baik ketika investor menggunakan kriteria bagaimana meminimalkan standar deviasi portofolio pada ekspektasi *return* portofolio yang dikehendaki investor. Sebagai tambahan, hasil optimisasi portofolio dari metode GRG berbasis MSwM-AR(1) juga bisa dijadikan pilihan kedua.

PENUTUP

Kesimpulan

Penggunaan algoritma GRG dengan MSwM based menghasilkan bobot portofolio berdasarkan fenomena "bull" and "bear" market, sehingga bobot portofolio yang terbentuk lebih realistis didalam pasar modal. Pada metode ini, fenomena "bull" and "bear" market dapat diidentifikasi ketika *regime* pada *return*

portofolio (bobot yang sama) diterapkan pada semua *return* saham. Pada penerapan portofolio, investasi dapat memberikan portofolio terbaik ketika risikonya dapat diminimalkan pada ekspektasi *return* tertentu.

Saran

Diberikan saran bahwa pengembangan penelitian dapat dilakukan dengan metode optimisasi lainnya, seperti *Genetic Algorithm* (GA), dll. Peneliti dapat mengembangkan investasi yang mempertimbangkan kriteria investor dan fenomena pasar modal lainnya. Saran buat investor adalah investasi saham dengan portofolio memiliki risiko yang lebih kecil daripada investasi saham secara individu, serta investor bisa menginvestasikan modalnya sesuai dengan bobot portofolio yang terbentuk.

DAFTAR PUSTAKA

- [1] F. Ariany, H. Kuswanto, dan Suhartono, "Estimasi Value at Risk pada Portofolio Nilai Tukar Mata Uang dengan Pendekatan Copula," *Jurnal Sains dan Seni ITS*, Vol. 1, No. 1(2012, Sep) 265-270.
- [2] E.Y. Astuti, "Implementasi Bayesian Markov Chain Monte Carlo pada Pemodelan Portofolio Optimal dengan Pendekatan Model Mixture dari Beberapa Mixture," M.S.thesis, Dept.Statistika, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia (2006).
- [3] S. Benninga, *Financial Modeling (3rd Edition)*, London: The MIT Press (2008).
- [4] L.D. Booth dan W.S. Cleary, *Introduction to Corporate Finance*, Canada: John Wiley and Sons (2010).
- [5] G.E.P. Box dan G.M. Jenkins, *Time Series Analysis: Forecasting and Control*, California: Holden-Day(1976).
- [6] P.H. Franses dan D.V. Dijk, *Non-linier Time Seres Model in Empirical Finance*, New York: Cambridge University Press (2000).
- [7] M.A. Hadiyat, "Pemodelan Markov Switching GARCH: Penerapan pada Return Index Dowjones," M.S.thesis, Dept.Statistika, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia (2007).



- [8] J.D. Hamilton, "A New Approach to the Economic Analysis of Nonstationary Time Series Subject to Changes in Regime". *Econometrica*, Vol. 57, No. 2 (1989, Mar) 357-384. *Jurnal Keuangan dan Perbankan*, Vol. 14, No. 3 (2010) 459-466.
- [9] J.D. Hamilton, "Analysis of Time Series Subject to Changes in Regime," *Econometrica*, Vol. 45, No. 1-2 (1990) 39-70.
- [10] J.D. Hamilton, *Time Series Analysis*. New Jersey: Princeton University Press (1994).
- [11] Pemerintah Republik Indonesia, "Undang-undang Republik Indonesia Nomor 8 Tahun 1995 Tentang Pasar Modal," Lembaran Negara Republik Indonesia Tahun 1995 Nomor 8, Tambahan Lembaran Negara Republik Indonesia Nomor 3608 (1995).
- [12] H.M. Markowitz, "Portfolio Selection," *Journal of Finance*, Vol. 7, No. 1 (1952) 77-91.
- [13] P. Jorion, *Value at Risk - The New Benchmark for Managing Financial Risk (3rd Edition)*, New York: The McGraw-Hill Companies (2007).
- [14] L.S. Lasdon, A.D. Waren, A. Jain, dan M. Ratner, "Design and Testing of a Generalized Reduced Gradient Code for Nonlinear Programming," *ACM Transactions on Mathematical Software*, Vol. 4, No. 1 (1978, Mar) 34-50.
- [15] A. Ravindran, K.M. Ragsdell, dan G.V. Reklaitis, *Engineering Optimization: Methods and Applications (2nd Edition)*, New Jersey: John Wiley & Sons (2006).
- [16] R.A. Sartono dan A.A. Setiawan, "VaR Portfolio Optimal: Perbandingan antara Metode Markowitz dan Mean Absolute Deviation," *Jurnal Siasat Bisnis*, Vol. 1, No. 1 (2006) 37-50.
- [17] I. Seidl, "Markowitz Versus Regime Switching: An Empirical Approach," *The Review of Finance and Banking*, Vol. 4, No. 1 (2012) 33-43.
- [18] S. Yuniarti, "Pembentukan Portofolio Optimal Saham-saham Perbankan dengan Menggunakan Model Indeks Tunggal,"



HALAMAN INI SENGAJA DIKOSONGKAN