Jurnal Derivat, Volume 6 No. 1 Juli 2019
ISSN: 2407 - 3792

PREDIKSI KURS RUPIAH TERHADAP DOLAR DENGAN FTS-MARKOV CHAIN DAN HIDDEN MARKOV MODEL

Maria Titah Jatipaningrum[1)], Kris Suryowati[2)] Libertania Maria Melania Esti Un [3)]
[1,2,3]*Jurusan Statistika, Institut Sains & Teknologi Akprind Yogyakarta, Indonesia*
Email : [1]titahjp@akprind.ac.id, [2]suryowati@akprind.ac.id, [3] libertaniamariamelaniaesti10@gmail.com

Abstrak

Hidden Markov model is a development of the Markov chain where the state cannot be observed directly (hidden), but can only be observed, a set of other observations and combination of fuzzy logics and markov chain to predict Rupiah exchange rate against the Dollar. The exchange rate of purchasing and exchange rate of saling is devided into four states, namely down large, down small, small rise, and large rise are symbolized respectively S1, S2, S3, and S4. Probability of sequences of observation for 3 days later are computed by Forward and Bacward Algorithm, determine the hidden state sequence using viterbi algorithm, and estimate the HMM parameters using baum Welch algorithm. The MAPE result exchange rate of purchase of FTS-Markov Chain is 1,355% and exchange rate of sale of FTS-Markov Chain is 1,317%. The sequences of observation which optimized within exchange rate of purchase is X = {S3,S3,S3}, within exchange rate of sale is also X* = {S3,S3,S3}.*

Keywords: Exchange rate, FTS-Markov Chain, Hidden Markov Model

1. Pendahuluan

Salah satu indikator penting dalam menganalisis perekonomian Indonesia adalah nilai tukar Rupiah terhadap Dolar Amerika Serikat. Nilai tukar menjadi penting karena mempunyai dampak yang luas terhadap perekonomian secara keseluruhan. Sebagai contoh, menurut [7] nilai tukar rupiah berpengaruh signifikan terhadap pergerakan Indeks Harga Saham Gabungan (IHSG). Hal ini dapat dijelaskan bahwa terjadinya apresiasi kurs Rupiah terhadap Dolar akan memberikan dampak terhadap perkembangan pemasaran produk Indonesia di luar negeri, terutama dalam hal persaingan harga [7]. Oleh karena itu, nilai tukar Rupiah sangat mempengaruhi stabilitas perekonomian di Indonesia.

Peneliti yang telah melakukan penelitian mengenai kurs Rupiah terhadap Dolar, [3] dengan judul Prediksi Pergerakan Nilai Tukar Rupiah Terhadap Dolar Amerika Serikat Menggunakan Hidden Markov Model. Hasil penelitian tersebut kurs beli dan kurs jual Rupiah Amerika Serikat terhadap Rupiah dapat dimodelkan dengan Hidden Markov Model (HMM). Prediksi kurs beli dari tiga hari ke depan semuanya sudah tepat, sedangkan kurs jual dari tiga hari prediksi hanya prediksi hari pertama yang masih kurang tepat.

Prediksi dengan Rantai Markov dilakukan oleh [2] dengan mengkombinasikan dengan logika fuzzy. Kelebihan dari Fuzzy Time Series Markov Chain, dapat menganalisis data linguistik atau data time series sampel kecil diusulkan supaya keakuratan prediksi lebih tinggi dengan mentransfer data time series ke grup logika fuzzy, dan menggunakannya untuk mendapatkan matriks peluang transisi Rantai Markov kemudian digunakan untuk peramalan data produk domestik bruto. Penelitian Hidden Markov model pernah dikaji dalam [1] yang diterapkan pada prediksi harga saham.

2. Kajian Teori

Peneliti yang telah melakukan penelitian mengenai kurs Rupiah terhadap Dolar, Mahmudi, Ardi (2016) dengan judul Prediksi Pergerakan Nilai Tukar Rupiah Terhadap Dolar Amerika Serikat Menggunakan Hidden Markov Model. Hasil penelitian tersebut kurs beli dan kurs jual Dolar Amerika Serikat terhadap Rupiah dapat dimodelkan dengan Hidden Markov Model (HMM). Prediksi kurs beli dari tiga hari ke depan semuanya sudah tepat, sedangkan kurs jual dari tiga hari prediksi hanya prediksi hari pertama yang masih kurang tepat.

Prediksi dengan Rantai Markov dilakukan oleh Jatipaningrum (2016) dengan mengkombinasikan dengan logika fuzzy. Kelebihan dari Fuzzy Time Series Markov Chain, dapat menganalisis data linguistik atau data time series sampel kecil diusulkan supaya keakuratan prediksi lebih tinggi dengan mentransfer data time series ke grup logika fuzzy, dan menggunakannya untuk mendapatkan matriks peluang transisi Rantai Markov kemudian digunakan untuk peramalan data produk domestik bruto. Jatipaningrum (2014) dalam penelitian tersebut divisualisasi rantai Markov waktu diskret dengan package R "Markovchain".

Penelitian Hidden Markov model pernah dikaji dalam Mamonto, S., Langi, Y., & Rindengan, A. (2016) yang diterapkan pada prediksi harga saham. Penelitian ini difokuskan pada prediksi kurs Rupiah terhadap Dolar dengan fuzzy hidden Markov Model.

3. Metode Penelitian

Metode analisis (Mahmudi, Ardi, 2016) meliputi :

a. Deskripsi data kurs Rupiah terhadap Dolar
b. Menghitung peluang observasi (Evaluation problem dengan algoritma Forward)
c. Menentukan barisan hidden state (Decoding problem dengan algoritma Viterbi)
d. Menaksir parameter- parameter HMM (Learning problem dengan algoritma Baum-Welch yang merupakan kasus khusus dari algoritma EM (Ekspektasi Maksimum)
e. Prediksi kurs Rupiah terhadap Dolar untuk tahun 2017-2020 dengan Fuzzy Hidden Markov Model.
f. Perhitungan MAPE (*Mean Average Percentage Error*).
g. Kesimpulan dan Interpretasi.

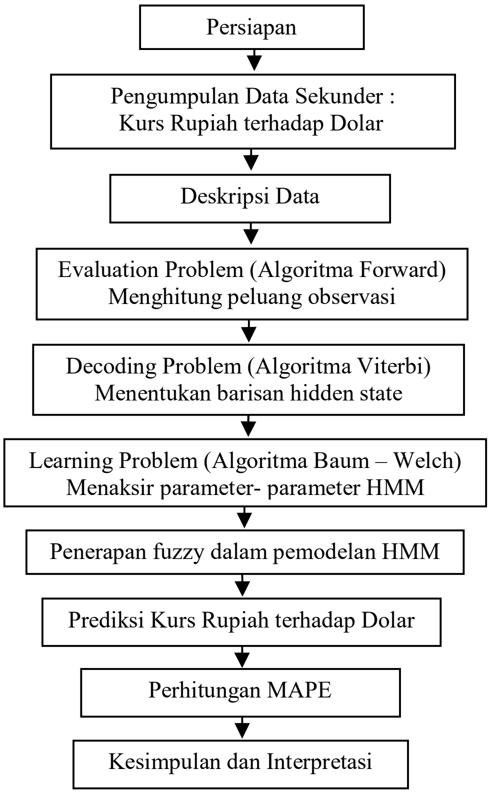

4. Hasil Dan Pembahasan

Fuzzy time series markov chain merupakan konsep baru yang pertama kali diusulkan oleh Tsaur, dalam penelitiannya untuk menganalisis keakuratan prediksi nilai tukar mata uang Taiwan dengan dolar US. Dalam penelitiannya Tsaur menggabungkan metode *fuzzy time series* dengan rantai markov, penggabungan tersebut bertujuan untuk memperoleh probabilitas terbesar menggunakan matriks probabilitas transisi. hasil penelitian tersebut menunjukkan bahwa metode *fuzzy time series markov chain* memberikan akurasi yang cukup baik.

Langkah-langkah menyelesaikan model fuzzy time series Markov chain dimana langkah 1 sampai 10 merupakan model fuzzy time series Markov Chain [5] dan [6], yaitu :

A. Mengumpulkan data (Yt)
B. Defenisikan *Universe of discourse* U berdasarkan jarak yang tersedia pada data historis runtun waktu, dengan aturan U = $[D_{min} - D_1, D_{max} + D_2]$ dimana D1 dan D2 merupakan dua bilangan positif yang tepat. Menentukan *interval I* menggunakan metode *average based length* dengan langkah-langkah berikut :

   Tahap 1 Hitung selisih D_t , D_{t-1} kemudian hitung rata-ratanya dengan rumus
   Tahap 2 Bagi dua nilai rata-rata.
   Tahap 3 Besar Interval I adalah pembulatan nilai B kemudian basis ditentukan berdasarkan tabel 3.2

Tabel 1. Tabel Pemetaan Basis

Range	***Base***
0.1-1.0	0.1
1.1-10	1
11-100	10
101-1000	100

C. Membagi (partisi) himpunan semesta U menjadi beberapa bagian dengan interval (n) yang sama dengan rumus sturges berikut :

$n = 1 + 3,322 \log N$ (3)

Dengan N adalah banyaknya data historis. Perbedaan antara dua interval berturut-turut dapat didefinisikan dengan *l* sebagai berikut :

$l = \frac{[(D_{max} + D_2) - (D_{min} - D_1)]}{n}$ (4)

Maka setiap interval diperoleh yaitu :

$u_1 = [D_{min} - D_1, D_{min} - D_1 + l]$
$u_2 = [D_{min} - D_1 + l, D_{min} - D_1 + 2l]$
$\vdots$
$u_n = [D_{min} - D_1 + (n-1)l, D_{min} - D_1 + nl]$

D. Membuat himpunan *fuzzy* A_i sesuai dengan interval pada langkah sebelumnya. Seluruh himpunan fuzzy dapat ditentukan berdasarkan dimana A_1, A_2 ,…, A_n didefinisikan sebagai beikut :

$A_1 = \{1/u_1 + 0.5/u_2 + 0/u_3 + \ldots + 0/u_n\}$

$A_2 = \{0.5/u_1 + 1/u_2 + 0.5/u_3 + \ldots + 0/u_n\}$

$\vdots$

$A_n = \{0/u_1 + \ldots + 0/u_{n-2} + 0.5/u_{n-1} + 1/u_n\}$

E. Fuzzifikasi data historis dan tentukan *fuzzy logical relationships* dengan aturan : jika A_i maka fuzzy menghasilkan bulan *n* dan A_j merupakan hasil fuzzifikasi tahun *n+1* maka *fuzzy logical relation* ditunjukkan sebagai $A_i \rightarrow A_j$ dimana A_i disebut keadaan sekarang dan A_j keadaan berikutnya.

F. Menentukan Fuzzy Logical Relation (FLR)

G. Menentukan Fuzzy Logical Relation (FLRG)

H. Perhitungan peramalan.
Untuk data *time series*, digunakan FLRG, yang mana informasinya digunakan untuk mendapatkan probabilitas *state* selanjutnya. Sehingga didapatkan matriks transisi markov, state n didefinisikan untuk setiap langkah waktu himpunan *fuzzy n* sehingga dimensi dari matriks transisi adalah *n x n*.
Dari matriks probabilitas yang didapat pada tahap sebelumnya, nilai peramalan awal dapat dihitung dengan aturan sebagai berikut :
Aturan 1. Jika FLRG A_i adalah kosong ($A_i \rightarrow \emptyset$) maka hasil peramalan $F(t)$ adalah m_i, yaitu nilai tengah dari u_i dengan persamaan : $F(t) = m_i$ (5)

Aturan 2. Jika FLRG A_i adalah satu ke satu ($A_i \rightarrow A_j$) maka hasil peramalan $F(t)$ adalah m_j, yaitu nilai tengah dari u_i dengan persamaan : $F(t) = m_j$ (6)

Aturan 3. Jika FLRG A_j adalah satu ke banyak ($A_j \rightarrow A_1, A_2, \dots, A_n$, $j = 1,2, \dots, n$) jika kumpulan data $Y(t-1)$ pada saat $t-1$ yang berada pada state A_i maka hasil peramalan $F(t)$ adalah sebagai berikut:

$$F(t) = m_1 P_{j1} + m_2 P_{j2} + \dots + m_{j-1} P_{j(j-1)} + Y(t-1) P_j + m_{j+1} P_{j(j+1)} + \dots + m_n P_{jn} \quad (7)$$

Dengan $m_1, m_2, \dots, m_{j-v}, m_{j+v}, \dots, m_n$ merupakan titik tengah dari $u_1, u_2, \dots, u_{j-v}, u_{j+v}, \dots, u_n$ dan titik tengah di substitusikan ke $Y(t-1)$ agar diperoleh state A_j saat $t-1$.

I. Mengatur kecenderungan nilai peramalan. Beberapa pengaturan nilai peramalan yang disarankan untuk memperbaiki error, yaitu :

1) Jika *state* A_i berkomunikasi dengan A_j , dimulai dari *state* A_i pada waktu *t-1* sebagai $Y_{(t-1)} = A_i$ dan membuat transisi menaik *state* A_j pada waktu *t* dimana *(i<j)* maka rumus pengaturan nilai kecenderungan adalah :

   $$D_{t1} = (l/2) \quad (8)$$

   Dimana,
   l adalah nilai basis interval.

2) Jika *state* A_i berkomunikasi dengan A_i , dimulai dari *state* A_i pada waktu *t-1* sebagai $Y_{(t-1)} = A_i$ dan membuat transisi menurun *state* A_j pada waktu t dimana *(i>j)* maka rumus pengaturan nilai kecenderungan adalah :

   $$D_{t1} = -(l/2) \quad (9)$$

3) Jika *state* A_i berkomunikasi dengan A_j , dimulai dari *state* A_i pada waktu *t-1* sebagai $Y_{(t-1)} = A_i$ dan membuat transisi menaik *state* A_j pada waktu *t* dimana *($1 \leq s \leq n-i$)* maka rumus pengaturan nilai kecenderungan adalah :

   $$D_{t1} = (l/2)s \quad (10)$$

   Dimana, s adalah jumlah lompatan ke depan

4) Jika *state* A_i berkomunikasi dengan A_i , dimulai dari *state* A_i pada waktu *t-1* sebagai $Y_{(t-1)} = A_i$ dan membuat transisi menurun *state* A_j pada waktu *t* dimana *($1 \leq v \leq i$)* maka rumus pengaturan nilai kecenderungan adalah :

   $$D_{t1} = -(l/2)v \quad (11)$$

   Dimana, v adalah jumlah lompatan ke belakang.

J. Menentukan hasil peramalan dengan nilai pengaturan kecendengan.

Jika *fuzzy logical relationship group* A_i adalah *one to many* dan *state* A_{i+1} dapat diakses dari A_i ke *state* A_j berkomunikasi dengan A_i maka hasil peramalan menjadi,

$$\hat{Y}_t = \hat{Y}1_t + D_{t1} * D_{t2} \quad (12)$$

Jika *fuzzy logical relationship group* A_i adalah *one to many* dan *state* A_{i+1} dapat diakses dari A_i ke *state* A_i berkomunikasi dengan A_i maka hasil peramalan menjadi,

$$\hat{Y}_t = \hat{Y}1_t + D_{t1} \quad (13)$$

Jika *fuzzy logical relationship group* A_i adalah *one to many* dan *state* A_{i+1} dapat diakses dari A_i ke *state* A_i berkomunikasi dengan A_i maka hasil peramalan menjadi,

$$\hat{Y}_t = \hat{Y}1_t + 2 * D_{t2} \qquad (14)$$

Tabel 2. Hasil prediksi FTS-MC untuk Kurs Jual dan Kurs Beli

	Hasil prediksi
Kurs Jual (01-Des-2018	14725,11
Kurs Beli (01-Des-2018	14590,44

Tabel 3. Hasil nilai MAPE FTS-MC untuk Kurs Jual dan Kurs Beli

	MAPE
Kurs Jual	1,317%
Kurs Beli	1,355%

Gambar 1. Plot hasil prediksi Kurs Jual

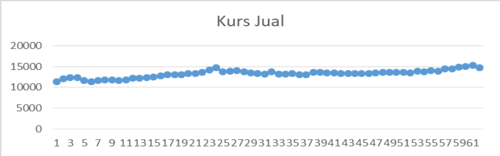

Pada plot tersebut, terlihat bahwa hasil prediksi untuk periode 1 Desember 2018 mengalami penurunan untuk kurs jual Rupiah terhadap Dolar yaitu sebesar 14725,11.

Gambar 1. Plot hasil prediksi Kurs Beli

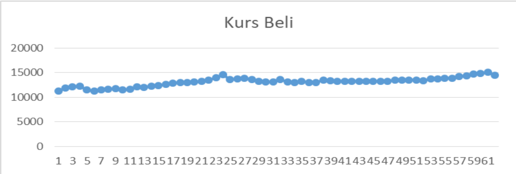

Pada plot tersebut, terlihat bahwa hasil prediksi untuk periode 1 Desember 2018 mengalami penurunan untuk kurs beli Rupiah terhadap Dolar yaitu sebesar 14590,44.

Proses hidden ini hanya dapat diamati melalui proses yang dapat diobservasi. Jika $X = \{X_1, X_2, \ldots\}$ adalah sebuah proses Markov, dan $O = \{O_1, O_2, \ldots\}$ adalah fungsi dari X, maka X adalah sebuah Hidden Markov Model yang dapat diobservasi melalui O, atau dapat ditulis $O = f(X)$ untuk suatu fungsi f. Parameter X menyatakan state process yang tersembunyi (hidden), sementara parameter O menyatakan proses observation yang dapat diobservasi.

HMM adalah sebuah proses stokastik ganda di mana salah satu prosesnya tidak dapat diobservasi (hidden). Proses yang tidak dapat diobservasi ini hanya dapat diobservasi melalui proses yang dapat diobservasi. Jika $X = \{X_1, X_2, \ldots\}$ adalah sebuah proses Markov, dan $O = \{O_1, O_2, \ldots\}$ adalah sebuah fungsi dari X, maka X adalah sebuah HMM yang dapat diobservasi melalui O, atau dapat ditulis $O = f(X)$ untuk suatu fungsi f. Parameter X menyatakan *state process* yang tersembunyi (hidden), sementara parameter O menyatakan observation process yang dapat diobservasi. Untuk ilustrasi HMM dapat dilihat pada

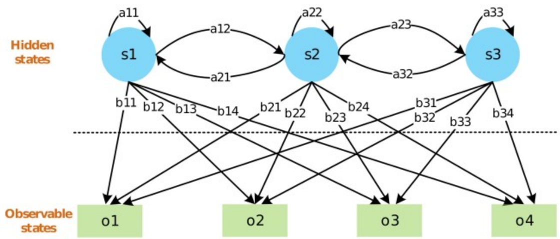

Gambar 1. Ilustrasi Hidden Markov Model [8]

HMM didefinisikan sebagai 5-tuple (5 pasangan di mana masing-masing anggota bisa berupa himpunan atau ukuran) sebagai berikut:

a. Banyaknya elemen keadaan tersembunyi (hidden state) pada model yang dinotasikan dengan N.
b. Matriks peluang transisi $A = \left[a_{ij}\right]$, di mana a_{ij} adalah elemen dari A yang merupakan peluang bersyarat dari keadaan pada saat $t+1$, jika diketahui keadaan X pada saat t, atau $a_{ij} = P\left(X_{t+1} = j \middle| X_t = i\right)$ di mana $1 \le i$, $j \le N$. Karena itu A berukuran $N \times N$ yang perlu dijadikan catatan bahwa $a_{ij} \ge 0$ untuk setiap $1 \le i$, $j \le N$ dan $\sum_{j=1}^{N} a_{ij} = 1$ untuk setiap $1 \le i \le N$. Artinya jumlah elemen masing-masing baris adalah satu.
c. Banyaknya elemen keadaan yang terobservasi, M. M umumnya tetap, ditentukan oleh pengamat, tetapi M juga bisa dimisalkan sebagai variabel acak. Misalkan variabel acak dari suatu keadaan terobservasi adalah K, $k = 1, 2, \ldots, M$
d. Distribusi peluang observasi pada saat t, pada keadaan i, yang biasa dikenal dengan matriks emisi $B = \{b_i(k)\}$, dimana

$$\begin{aligned} b_i^k &= b_i \cdot (k) \\ &= P\left(O_t = v_m \middle| O_t = s_j\right), 1 \le i \le N \text{ dan } 1 \le k \le M \end{aligned} \tag{15}$$

K adalah observasi pada waktu ke- t bernilai k, jadi B adalah matriks berukuran $(N \times M)$, dan seperti pada matriks transisi A, jumlah elemen setiap baris adalah 1.
e. Keadaan awal $\pi = \{\pi(i)\}$ di mana $\pi(i) = P(X_1 = i), 1 \le i \le N$

Istilah tuple di atas berkaitan dengan himpunan dan ukuran. Pada HMM himpunannya diwakili oleh variable acak. Dari definisi di atas, cukup jelas bahwa dari nilai 5 tuple, (N, M, A, B, π), terdapat 3 komponen yang merupakan ukuran probabilitas, yaitu A, B, π.

Akibatnya HMM lebih dikenal dengan notasi $\lambda = (A, B, \pi)$, dengan A berukuran $N \times N$ dan B berukuran $N \times M$.

Elemen – elemen dari Hidden Markov Model seperti dikutip pada [4] adalah:

a. N, jumlah state, dengan ruang state $S = \{s_1, s_2, \ldots\}$ dan state pada waktu t dinyatakan Q_t.
b. M, jumlah pengamatan observasi tiap state, dengan ruang observasi $V = \{v_1, v_2, \ldots\}$
c. $A = [a_{ij}]$, matriks peluang transisi
d. $B = [b_{ij}]$, matrik peluang bersyarat observasi v_m, jika proses berada pada state j, dimana:

$$b_{jm} = b_j \cdot (O_t) = P(O_t = v_m | O_t = s_j), 1 \leq j \leq N \text{ dan } 1 \leq m \leq M \quad (16)$$

e. π_i, yaitu distribusi state awal.

Ada tiga permasalahan khusus yang dicari solusinya dengan metode Hidden Markov Model, yaitu:

a. Evaluasi problem, merupakan perhitungan peluang dari urutan nilai observasi yang diberikan oleh Hidden Markov Model, masalah ini dapat diselesaikan dengan algoritma Forward dan Backward.
b. Decoding Problem Pengertian dari decoding problem dalam Hidden Markov Model adalah penarikan kesimpulan berdasarkan asumsi yang diperoleh dari nilai probabilitas observasi yang didapat sebelumnya pada operasi evaluasi. Operasi ini juga sering kali digunakan untuk mencari nilai optimum. Masalah ini dapat diselesaikan dengan Algoritma Viterbi.
c. Learning Problem Pengertian dari operasi learning dalam Hidden Markov Model adalah membuat parameter- parameter baru Hidden Markov Model jika diberikan dataset barisan-barisan tertentu agar dapat menemukan himpunan transisi state yang paling mungkin beserta probabilitas hasilnya.

Hasil taksiran matriks Hidden State untuk Kurs Jual dan Kurs Beli

$$\text{Matriks Hidden } (\hat{A}) = \begin{bmatrix} 0{,}163 & 0{,}245 & 0{,}3 & 0{,}292 \\ 0{,}156 & 0{,}233 & 0{,}32 & 0{,}291 \end{bmatrix}$$

Hasil taksiran matriks Observed untuk Kurs Jual dan Kurs Beli

$$\text{Matriks Observed } (\hat{B}) = \begin{bmatrix} 0{,}593 & 0{,}407 \\ 0{,}612 & 0{,}388 \end{bmatrix}$$

Model HMM dapat digunakan untuk waktu yang akan datang tanpa menentukan ulang parameter input maka dilakukan penaksiran parameter-parameter HMM yang optimal dari data yang diolah dengan menggunakan algoritma *Baum-Welch*. Dari hasil pengolahan menggunakan algoritma *Baum-Welch* diperoleh:

a. Barisan Observasi yang memiliki nilai peluang terbesar : O = {naik,naik,naik} atau O = {2,2,2}
b. Barisan observasi yang paling optimal : X* = {S3,S3,S3}
c. Nilai taksiran peluang keadaan awal untuk t = 1, yaitu:

$$\hat{\pi} = \begin{bmatrix} 0 \\ 0 \\ 0{,}58 \\ 0{,}42 \end{bmatrix}$$

Nilai diatas adalah taksiran peluang awal. Artinya agar nilai $P(O|\hat{\lambda}) \geq P(O|\lambda)$ terpenuhi, maka probabilitas proses berada pada state S1 adalah sebesar 0; untuk state S2 sebesar 0; untuk state S3 sebesar 0,58; dan untuk state S4 sebesar 0,42.

d. Taksiran matriks transisi atau Hidden matriks $\hat{A}$, yaitu: Matriks tersebut menggambarkan bahwa untuk mencapai nilai $P(O|\hat{\lambda}) \geq P(O|\lambda)$ maka probabilitas transisi dari kurs jual Rupiah dan kurs beli Dolar pada state S3 ke state S1 sebesar 0,163; dari state S4 ke state S2 sebesar 0,233 dan seterusnya bisa dilihat pada matriks $\hat{A}$.

e. Taksiran matriks emisi atau matriks observed $\hat{B}$, yaitu: Matriks tersebut menggambarkan bahwa untuk mencapai nilai $P(O|\hat{\lambda}) \geq P(O|\lambda)$ maka probabilitas transisi dari kurs jual Rupiah pada state S3 saat besok kurs jual Rupiah sebesar 0,163 dan seterusnya bisa dilihat pada matriks $\hat{B}$.

5. Kesimpulan

Berdasarkan hasil dan pembahasan yang telah diuraikan sebelumnya, dapat disimpulkan sebagai berikut:

1. Hasil prediksi untuk kurs jual Rupiah terhadap Dolar pada periode 1 Desember 2018 dengan menggunakan metode FTS-MC adalah sebesar 14725,11 dengan tingkat keakuratan prediksi nilai MAPE sebesar 1,317% dan hasil prediksi untuk kurs beli Rupiah terhadap Dolar pada periode 1 Desember 2018 sebesar 14590,44 dengan tingkat keakuratan prediksi nilai MAPE sebesar 1,355%.
2. Barisan Observasi yang memiliki nilai peluang terbesar : O = {naik,naik,naik} atau O = {2,2,2}
3. Barisan observasi yang paling optimal untuk kurs jual dan beli Rupiah terhadap Dolar adalah X* = {S3,S3,S3}.
4. Kurs beli dan kurs jual dapat dimodelkan dengan *Hidden Markov Model* (HMM).

6. Referensi

Febriani, E., Jondri, J., & Saepudin, D. (2016). Peramalan Harga Saham Menggunakan Principal Component Analysis Dan Hidden Markov Model. *eProceedings of* Engineering, 3(3).

Jatipaningrum, M.T. (2016). *Peramalan Data Produk Domestik Bruto Dengan Fuzzy Time Series Markov Chain.* Publikasi online Jurnal Teknologi, ISSN: 1979-3906; ISSN online : 2338-6711 ; Volume 9 Nomor 1, Juni 2016; Institut Sains & Teknologi AKPRIND Yogyakarta ; halaman 31-38.

Mahmudi, Ardi (2016). Prediksi Pergerakan Nilai Tukar Rupiah Terhadap Dolar Amerika Serikat Menggunakan Hidden Markov Model. Jurnal LOGIKA, Jilid 6, No. 1, 2016, Hal. 32 - 41 ISSN 1978 – 8568.

Mamonto, S., Langi, Y., & Rindengan, A. (2016). Penerapan Hidden Markov Model Pada Harga Saham. *de CARTESIAN*, *5*(1), 35-41.

Pratikno, Dedy. 2006. Analisis Pengaruh Nilai Tukar Rupiah, Inflasi, SBI, dan Indeks Dow Jones Terhadap Pergerakan Indeks Harga Saham Gabungan (IHSG) di Bursa Efek Indonesia (BEI). Jurnal Riset Ekonomi dan Manajemen

Song, Q dan Chissom, B. S,1993, *Forecasting Enrollment With Fuzzy Time Series- Part. Fuzzy sets and systems*, 54(1): 1-9.

Tsaur. R. C, 2012, *A Fuzzy Time Series-Markov Chain Model With an Application to Forecast thr Exchange Rate Between the Taiwan and US Dollar*. International journal of innovative.

Zucchini, W., MacDonald, I. L., & Langrock, R. (2017). *Hidden Markov models for time series: an introduction using R*. CRC press.