



Perbandingan FTS Cheng dan FTS Markov Chain Penemuan Model untuk Memprediksi Tingkat Pengangguran Terbuka di Bali

Kadek Tresna Dwipayana^{*}, I Gusti Nyoman Yudi Hartawan, I Made Candiasa

Department of Mathematics, Universitas Pendidikan Ganesha, Indonesia

^{*} Corresponding Author. E-mail: tresna.dwipayana@undiksha.ac.id

ARTICLE INFO

Article History:

Received: 01-Aug. 2022

Revised: 23-Oct. 2022

Accepted: 12-Dec. 2022

Keywords:

Fuzzy time series cheng,
fuzzy time series markov
chain, tingkat
pengangguran terbuka.

ABSTRACT

Penelitian ini bertujuan menemukan model untuk tingkat pengangguran terbuka di Bali dengan *Fuzzy Time series Cheng* (FTS Cheng) dan *Fuzzy Time series Markov Chain* (FTS Markov Chain) serta membandingkan tingkat akurasi kedua model tersebut. Jenis penelitian ini adalah jenis penelitian penambangan data. Data tingkat pengangguran terbuka di Bali yang digunakan sebanyak 34 dari periode Februari 2006 sampai dengan Agustus 2021. Dari 34 data kemudian dibagi menjadi dua dengan proporsi 30% data latih dan 70% data uji. Tahapan penelitian yang dilakukan dengan menghitung FTS Cheng dan FTS Markov Chain pada data latih kemudian dilanjutkan pada data uji. Selanjutnya model FTS Cheng dan FTS Markov Chain dihitung akurasinya dengan MAPE (*Mean Absolute Percentage Error*), RMSE (*Root Mean Square Error*) dan *Confusion Matrix* (akurasi, presisi, *recall*). Hasil MAPE yang didapatkan adalah FTS Cheng sebesar 18.43% dan FTS Markov Chain sebesar 31.19%. Kemudian hasil RMSE yang didapatkan dari FTS Cheng dan FTS Markov Chain secara berturut-turut adalah 0.88 dan 0.63. Pada pengujian menggunakan *Confusion Matrix* pada FTS Ceng didapatkan hasil akurasi, presisi, *recall* secara berturut-turut adalah 61.90%, 41.22%, dan 44.35%. Sedangkan untuk FTS Markov Chain mendapatkan hasil pengujian sebesar 61.90%, 49.17%, dan 48.75% untuk akurasi, presisi dan *recall*. Jadi *Fuzzy Time Series Markov Chain* lebih baik dibandingkan dengan model *Fuzzy Time Series Cheng* di dua metode pengujian keakuratan yaitu pada RMSE dan *Confusion Matrix* (presisi dan *recall*). Hal ini disebabkan karena perbedaan pembagian kelas serta perhitungan yang berbeda.

This research to find a model for the open unemployment rate in Bali using the Fuzzy Time series Cheng (FTS Cheng) and the Fuzzy Time series Markov Chain (FTS Markov Chain) and to compare the accuracy of the two models. This type of research is a type of quantitative research. The data on the open unemployment rate in Bali used were 34 from the period February 2006 to August 2021. From the 34 data then divided into two with a proportion of 30% training data and 70% test data. The research stages were carried out by calculating the FTS Cheng and FTS Markov Chain on the training data and then proceeding to the test data. Furthermore, the FTS Cheng and FTS Markov Chain models were calculated for accuracy with MAPE (Mean Absolute Percentage Error), RMSE (Root Mean Square Error) and Confusion Matrix (accuracy, precision, recall). The MAPE results obtained are FTS Cheng at 18.43% and FTS Markov Chain at 31.19%. Then the RMSE results obtained from FTS Cheng and FTS Markov Chain are 0.88 and 0.63, respectively. In testing using the Confusion Matrix on FTS Ceng, the results of accuracy, precision, recall are 61.90%, 41.22%, and 44.35%, respectively. As for FTS Markov Chain, the test results were 61.90%, 49.17%, and 48.75% for accuracy, precision, and recall. So, the Fuzzy Time Series Markov Chain is better than the Fuzzy Time Series Cheng model in two accuracy testing methods, namely the RMSE and Confusion Matrix (precision and recall). This is due to differences in class divisions and different calculations.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



How to Cite:

Dwipayana, K. T., Hartawan, I. G. N. Y., & Candiasa, I. M. (2022). Perbandingan FTS Cheng dan FTS Markov Chain pada prediksi tingkat pengangguran terbuka di Bali. *Pythagoras: Jurnal Matematika dan Pendidikan Matematika*, 17(2), 415-424. <https://doi.org/10.21831/pythagoras.v17i2.52335>

<https://doi.org/10.21831/pythagoras.v17i2.52335>

PENDAHULUAN

Di Indonesia masalah pengangguran masih menjadi persoalan yang belum terselesaikan. Pengangguran biasanya disebabkan oleh kurangnya lapangan pekerjaan yang tersedia daripada pencari kerja. Pengangguran adalah keadaan di mana seseorang yang termasuk dalam angkatan kerja yang belum atau sedang mencari pekerjaan (Prasetyo & Rakhmadian, 2019). Banyak jenis pengangguran yang ada di Indonesia salah satunya adalah pengangguran terbuka. Pengangguran terbuka adalah jenis pengangguran yang disebabkan oleh pertumbuhan lapangan pekerjaan yang lebih rendah dari penambahan tenaga kerja. Sedangkan tingkat pengangguran terbuka adalah persentase jumlah pengangguran terhadap jumlah angkatan kerja (BPS, 2021). Tingkat Pengangguran terbuka ini biasanya digunakan untuk mengukur ketersediaan lapangan pekerjaan terhadap tenaga kerja. Di provinsi Bali rata-rata tingkat pengangguran terbuka tidak lebih dari enam persen berdasarkan data yang dikumpulkan dari Badan Pusat Statistik (BPS). Namun beberapa bulan terakhir tepatnya bulan agustus tahun 2021 berdasarkan data BPS tingkat pengangguran terbuka mengalami kenaikan yang cukup pesat yakni sekitar 5%. Namun terkadang dalam pembaharuan data memerlukan waktu yang lama. Oleh sebab itu, dibutuhkan solusi agar mendapatkan informasi lebih awal untuk menghemat waktu sehingga kinerja dari pihak terkait lebih efisien. Salah satu solusinya yaitu dengan meramalkan atau memprediksi tingkat pengangguran di Bali menggunakan metode yang akurasiya bagus. Dengan memprediksi tingkat pengangguran terbuka di Bali, dapat membantu pemerintah provinsi Bali dalam membuat perencanaan program pemerintah ataupun kebijakan-kebijakan yang terkait tentang lapangan pekerjaan.

Prediksi merupakan proses memperkirakan sesuatu secara sistematis yang akan terjadi pada masa depan berdasarkan data informasi dari masa lalu atau sekarang yang dimiliki, sehingga mendapatkan hasil perkiraan yang mendekati hasil nyatanya (Habibi & Suryansah, 2020). Salah satu metode untuk dapat digunakan untuk memprediksi adalah Analisis Data *Time Series*. Jenis-jenis metode analisis *time series* antara lain adalah *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA), ataupun *Autoregressive Integrated Moving Average* (ARIMA).

Menurut Song, *time series* konvensional tidak mampu menyelesaikan persoalan tentang nilai-nilai linguistic (Song & Chissom, 1993). Nilai linguistik adalah nilai yang mewakili suatu kondisi atau keadaan tertentu dengan menggunakan bahasa alami, seperti harga rendah, sedang, tinggi. Kemudian, Song memberikan contoh ketika mengamati cuaca di sekitar maka kita akan sering menggunakan kata-kata verbal seperti sangat dingin, dingin, agak panas, dan panas. Jika kita mencatat pengamatan cuaca dalam hal nilai-nilai linguistik setiap hari, kita peroleh data yang nilainya berupa nilai linguistik atau kata dengan makna samar/kabur, dan seiring waktu berubah, nilai pengamatan ini juga berubah. Karena nilai-nilai linguistik ini dapat diterjemahkan menjadi himpunan fuzzy. Sehingga deret seperti ini benar-benar berbeda dari *time series* konvensional dan tidak ada model *time series* yang dapat menyelesaikannya (Song & Chissom, 1993). Oleh karena itu, dibuatkan model *fuzzy time series* oleh Song & Chissom. *Fuzzy Time series* merupakan pengembangan dari konsep *fuzzy* yang diperkenalkan oleh Zadeh (Song & Chissom, 1993; Tsaour & Kuo, 2011). Perbedaan *time series* konvensional dengan *fuzzy time series* terletak pada nilai yang digunakan dalam peramalan, pada *fuzzy time series* yang merupakan himpunan fuzzy dari bilangan-bilangan riil atas himpunan semesta yang ditentukan. Keuntungan dari metode ini adalah proses perhitungannya tidak terlalu rumit seperti pada algoritma genetika dan jaringan saraf, sehingga metode ini mudah dikembangkan (Singh, 2007). *Fuzzy time series* dikembangkan pertama kali oleh Song dan Chissom pada tahun 1993.

Penelitian terkait penerapan *fuzzy time series* di Indonesia juga sudah banyak dilakukan, di antaranya penelitian yang dilakukan oleh Saputra dkk tentang penerapan metode *fuzzy time series Markov Chain* untuk peramalan hasil budidaya ikan (Saputra, 2019). Penelitian tentang peramalan menggunakan metode *fuzzy time series* Cheng studi kasus Indeks Harga Saham Gabungan (IHSG) oleh Sumartini (Sumartini et al., 2017). Beberapa penelitian juga membandingkan kedua metode tersebut diantaranya oleh Noviani tentang perbandingan metode *fuzzy time series* Cheng dan *Markov Chain* studi kasus harga rata-rata beras (Noviani, 2021), Mustika tentang perbandingan metode *fuzzy time series* Cheng dan *Markov Chain* pada peramalan nilai tukar petani (NTP) di Indonesia (Mustika, 2021), dan Hidayatullah tentang perbandingan metode *fuzzy time series Markov Chain* dan *fuzzy time series* Cheng dalam meramalkan nilai tukar rupiah terhadap dolar Amerika Serikat (Muhammad, 2022).

METODE

Penelitian ini bertujuan untuk mengetahui model matematika pada tingkat pengangguran terbuka di Bali dengan *fuzzy time series Cheng* dan *fuzzy time series Markov Chain* serta membandingkan tingkat akurasi kedua model tersebut. Jenis penelitian ini adalah jenis penelitian kuantitatif. Metode pengumpulan data yang digunakan dalam penelitian ini adalah dokumenter dengan data sekunder. Data sekunder adalah data yang didapatkan melalui pihak kedua atau media perantara. Data penelitian ini diambil secara *online* dari situs <http://bali.bps.go.id> yang bersumber dari Badan Pusat Statistik Provinsi Bali. Penelitian ini menggunakan data tingkat pengangguran di Bali pada tahun 2006 sampai 2021. Terdapat 34 data yang akan dibagi menjadi 2 dengan proporsi 30% data latihan dan 70% data uji. Pembagian data ini dilakukan untuk melatih algoritma dan mengurangi fluktuasi data yang signifikan.

Fuzzy Time Series (FTS) Cheng

Menurut Fauziah metode *fuzzy time series Cheng* mempunyai teknik yang sedikit berbeda dengan *fuzzy time series* lainnya dalam menentukan interval, yaitu melihat dari segi frekuensi data dari tiap interval kemudian memberikan bobot berdasarkan pada urutan dan pengulangan FLR yang sama (Fauziah et al., 2019). Adapun tahapan-tahapan dalam prediksi dengan *fuzzy time series Cheng* adalah sebagai berikut (Cheng et al., 2008):

Langkah 1. Menentukan himpunan semesta (U) dengan persamaan

$$U = [D_{\min} - D_1, D_{\max} + D_2] \tag{1}$$

Langkah 2. Kemudian membaginya menjadi beberapa interval dengan jarak yang sama dengan menggunakan rumus *sturges* sebagai berikut :

$$n = 1 + 3,322 \log N \tag{2}$$

Kemudian menghitung banyaknya data yang termuat dalam setiap interval. Jika rata-rata dari banyaknya data lebih besar dari data yang termuat di interval maka bagi dua interval tersebut agar lebih kecil dari rata-rata banyaknya data setiap interval.

Langkah 3. Mendefinisikan himpunan-himpunan *fuzzy* seperti berikut.

$$\begin{aligned} A_1 &= \frac{1}{u_1} + \frac{0,5}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \dots + \frac{0}{u_n} \\ A_2 &= \frac{0,5}{u_1} + \frac{1}{u_2} + \frac{0,5}{u_3} + \frac{0}{u_4} + \dots + \frac{0}{u_n} \\ &\dots \\ A_n &= \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \dots + \frac{0,5}{u_{n-1}} + \frac{1}{u_n} \end{aligned}$$

(3)

dan melakukan *fuzzifikasi* data historis.

Langkah 4. Menentukan *Fuzzy Logic Relationship* (FLR).

Di langkah ini menentukan hubungan dari setiap datum yang sudah di *fuzzifikasi*. Misalnya datum ke tiga termasuk dalam A_3 dan datum kedua A_2 maka FLR di datum ketiga yaitu $A_2 \rightarrow A_3$.

Langkah 5. Mengelompokkan *Fuzzy Logic Relationship Group* (FLRG). FLR dengan LHSs (*Left Hand Sides*) yang sama dapat dikelompokkan untuk membentuk grup FLR (FLRG). Misalkan suatu data memiliki FLR $A_1 \rightarrow A_1, A_1 \rightarrow A_2, A_1 \rightarrow A_2$ sehingga FLRG nya $A_1 \rightarrow A_1, A_2$.

Langkah 6. Menentukan bobot pada FLRG. Misalkan suatu data memiliki FLR $A_1 \rightarrow A_1, A_1 \rightarrow A_2, A_1 \rightarrow A_2$ maka bobot pada FLRG yaitu $A_1 \rightarrow A_1$ diberikan bobot 1, $A_1 \rightarrow A_2$ diberikan bobot 2.

Langkah 7. Membentuk matriks bobot dinormalisasi. Berdasarkan langkah sebelumnya, maka bobot pada FLR tersebut akan di ubah ke dalam matriks pembobotan yang telah dinormalisasi ($W_n(t)$), yang persamaannya dituliskan sebagai berikut:

$$W_n(t) = [W'_1, W'_2, \dots, W'_k]$$

$$= \left[\frac{W'_1}{\sum_{h=1}^i W_h}, \frac{W'_2}{\sum_{h=1}^i W_h}, \dots, \frac{W'_k}{\sum_{h=1}^i W_h} \right] \quad (4)$$

Langkah 8. Menghitung nilai prediksi awal.

Untuk menghitung nilai prediksi, maka matriks pembobotan yang dinormalisasi ($W_n(t)$) dikalikan dengan matriks defuzzifikasi (L_{df}), dengan persamaan berikut:

$$F(t) = L_{df}(t-1)W_n(t-1) \quad (5)$$

dimana L_{df} didefinisikan sebagai berikut:

$$L_{df} = [m_1, m_2, \dots, m_k] \quad (6)$$

dengan m_1, m_2, \dots, m_k adalah nilai tengah dari u_1, u_2, \dots, u_k .

Langkah 9. Menghitung nilai prediksi dengan persamaan *adaptive forecasting*. Untuk menghitung nilai prediksi adaptif ($P(t)$) yaitu dengan persamaan berikut:

$$P(t) = Y(t-1) + h*(F(t) - Y(t-1)) \quad (7)$$

$Y(t-1)$ adalah data pengamatan pada saat $t-1$. Untuk h adalah parameter pembobotan yang berkisar $[0,001 - 1]$ (Fauziah et al., 2019).

Fuzzy Time Series (FTS) Markov Chain

Dalam model *fuzzy time series Markov Chain*, matriks peluang transisi digunakan sebagai dasar perhitungan prediksi. Berikut adalah langkah-langkah prediksi pada metode fuzzy time series Markov Chain (Tsauro, 2012; Tsauro & Kuo, 2011):

Langkah 1 sampai 5 sama dengan langkah pada FTS Cheng hanya saja pada langkah kedua tidak berisi pembagian interval menjadi dua ketika frekuensi interval ada yang lebih besar dari rata-rata frekuensi kelas interval.

Langkah 6. Menghitung nilai prediksi awal.

Langkah pertama yaitu menentukan matriks probabilitas transisi R dari *state*. Matriks probabilitas transisi didefinisikan sebagai berikut:

$$R = \begin{pmatrix} P_{11} & P_{12} & \dots & P_{1n} \\ P_{21} & P_{22} & \dots & P_{2n} \\ \dots & \dots & \dots & \dots \\ P_{n1} & P_{n2} & \dots & P_{nn} \end{pmatrix} \quad (8)$$

dengan P_{ij} adalah probabilitas transisi dari *state* A_i ke A_j yang didefinisikan sebagai berikut:

$$P_{ij} = \frac{M_{ij}}{M_i}, i, j = 1, 2, 3, \dots, n \quad (9)$$

dengan

M_{ij} : waktu transisi dari *state* A_i ke A_j dengan satu langkah

M_i : jumlah data dari *state* A_i

Aturan 1. Jika Fuzzy Logical Relationship Group (FLRG) dari A_i hanya bertransisi ke satu *state* (one to one) (yaitu, $A_i \rightarrow A_k$ dengan $P_{ik} = 1, P_{ij} = 0, j \neq k$) maka prediksi dari $F(t)$ adalah nilai tengah dari u_k , yaitu m_k , dengan persamaan:

$$F(t) = m_k P_{ik} = m_k \tag{10}$$

Aturan 2. Jika Fuzzy Logical Relationship Group (FLRG) dari A_i bertransisi ke banyak state (*one to many*) (yaitu, $A_i \rightarrow A_1, A_2, A_3, \dots, A_n, i = 1, 2, 3, \dots, n$), ketika data $Y(t-1)$ berada di state A_i , maka hasil prediksi untuk $F(t)$ adalah sebagai berikut:

$$F(t) = m_1 P_{i1} + m_2 P_{i2} + \dots + m_{i-1} P_{i(i-1)} + Y(t-1) P_{ii} + m_{i+1} P_{i(i+1)} + \dots + m_n P_{in} \tag{11}$$

di mana $m_1, m_2, \dots, m_{i-1}, m_{i+1}, \dots, m_n$ merupakan nilai tengah dari $u_1, u_2, \dots, u_{i-1}, u_{i+1}, \dots, u_n$.

Langkah 7. Menyesuaikan nilai kecenderungan prediksi.

Aturan penyesuaian kecenderungan untuk nilai prediksi dijelaskan sebagai berikut:

Aturan 3. Jika $Y(t-1) = A_i, Y(t) = A_j$, state A_i membuat transisi naik ke state A_j ($i < j$), dan A_i berkomunikasi (communicate) dengan A_j , maka nilai penyesuaian D_t didefinisikan sebagai:

$$D_{t1} = \frac{l}{2} \tag{12}$$

Aturan 4. Jika $Y(t-1) = A_i, Y(t) = A_j$, state A_i membuat transisi turun ke state A_j , ($i > j$), dan state A_i berkomunikasi dengan A_j , maka nilai penyesuaian D_t didefinisikan sebagai:

$$D_{t1} = -\frac{l}{2} \tag{13}$$

Aturan 5. Jika $Y(t-1) = A_i$, dan state A_i membuat transisi lompatan maju ke state A_{i+s} pada waktu t , ($1 \leq s \leq n-1$) maka nilai penyesuaian D_t didefinisikan sebagai:

$$D_{t2} = \left(\frac{l}{2}\right)s, (1 \leq s \leq n-1) \tag{14}$$

Aturan 6 Jika $Y(t-1) = A_i$ dan state A_i mengalami transisi lompatan mundur ke state A_{i-v} pada waktu t , ($1 \leq v \leq i$), nilai penyesuaian D_t didefinisikan sebagai:

$$D_{t2} = -\left(\frac{l}{2}\right)v, (1 \leq v \leq i) \tag{15}$$

Langkah 8. Menentukan nilai prediksi akhir.

$$F'(t) = F(t) \pm D_{t1} \pm D_{t2} = F(t) \pm \frac{l}{2} \pm \left(\frac{l}{2}\right)v \tag{16}$$

Pengujian Keakuratan

Setelah menerapkan kedua model selanjutnya adalah menghitung keakuratan masing-masing model dengan menggunakan tiga metode yaitu

1. *Mean Absolute Percentage Error* (MAPE)

Apabila nilai MAPE semakin kecil, maka tingkat keberhasilan metode prediksi dikatakan semakin tinggi. Perhitungan MAPE ditunjukkan pada persamaan berikut (Fauziah et al., 2019).

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{Y(t) - F(t)}{Y(t)} \right| \times 100\% \tag{17}$$

Keterangan:

- $Y(t)$: Nilai yang sebenarnya pada waktu t
- $F(t)$: Nilai hasil prediksi pada waktu t
- N : banyaknya data

Kriteria keakuratan dengan menggunakan nilai MAPE dapat dilihat pada Tabel 1.

Tabel 1. Kriteria keakuratan MAPE

Nilai MAPE	Kriteria Keakuratan
< 10%	Sangat Baik
10% – 20%	Baik
20% – 50%	Cukup
> 50%	Buruk

2. *Root Means Square Error* (RMSE)

Untuk RMSE apabila semakin kecil nilai RMSE maka nilai prediksi mendekati nilai aktual. Berikut persamaan yang digunakan untuk menghitung RMSE (Bramer, 2007; Chai & Draxler, 2014).

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (Y(t) - F(t))^2} \quad (18)$$

N = Banyaknya data

$Y(t)$ = nilai aktual

$F(t)$ = nilai prediksi

3. *Confusion Matrix*

Confusion matrix adalah tabel silang untuk mencatat kemampuan model dalam memprediksi dan mengevaluasi nilai prediksi terhadap nilai aktua (Grandini et al., 2020) | . Contoh *confusion matrix* berukuran 2x2 dapat dilihat pada Tabel 2.

Tabel 2. Confusion Matrix 2x2

Kelas	Positive	Negative
Positive	TP	FN
Negative	FP	TN

Keterangan :

True Positive (TP) adalah jika data yang diprediksi bernilai positif dan sesuai dengan nilai aktual (positif).

True Negative (TN) adalah jika benar antara prediksi negatif dan kenyataannya negatif

False Positive (FP) adalah jika data yang diprediksi tidak sesuai dengan nilai actual

False Negative (FN) adalah jika yang diprediksi bernilai negatif dan aktualnya positif.

Adapun *confusion matrix* dapat untuk menentukan akurasi, presisi, dan *recall*.

Akurasi adalah tingkat keakuratan/kedekatan dengan nilai aktual pada model, berikut persamaan untuk menghitungnya,

$$\text{akurasi} = \frac{TP + TN}{TP + TN + FN + FP} \times 100\% \quad (19)$$

Presisi adalah suatu ukuran pada kelas positif yang sebenarnya positif, berikut persamaan untuk menghitungnya,

$$\text{presisi} = \frac{TP}{TP + FP} \times 100\% \quad (20)$$

Recall adalah suatu ukuran pada kelas positif yang di prediksi negatif, berikut persamaan untuk menghitungnya,

$$\text{recall} = \frac{TP}{TP + FN} \times 100\% \quad (21)$$

HASIL PENELITIAN

Hasil prediksi dengan data latih

Prediksi dengan data latih sebanyak 10 dengan menggunakan $d_1 = 0,93$ dan $d_2 = 0,96$ dan menerapkan langkah-langkah pada bab sebelumnya maka didapatkan hasil seperti pada table di bawah ini.

Tabel 3. Hasil prediksi data latih

t	Tahun	TPT(%)	Prediksi Akhir model FTS Cheng (%)	Prediksi akhir model FTS Markov Chain (%)
1	Februari 2006	5,32	0	****
2	Agustus 2006	6,04	6,264	6
3	Februari 2007	4,89	4,808	5,5
4	Agustus 2007	3,77	3,778	3
5	Februari 2008	4,56	3,854	4,135
6	Agustus 2008	3,31	3,712	3
7	Februari 2009	2,93	3,162	2,905
8	Agustus 2009	3,13	3,186	4
9	Februari 2010	3,57	3,126	3,315
10	Agustus 2010	3,06	3,814	3,535

Tabel 4. Perbandingan akurasi hasil prediksi pada data latih

Metode	MAPE (%)	RMSE	Confusion Matrix		
			Akurasi (%)	Presisi (%)	Recall (%)
FTS Cheng	8,89	0,41	44,44	43,06	38,89
FTS Markov Chain	11,51	0,50	77,78	90	66

Dapat diperhatikan pada Tabel 3 hasil prediksi kedua metode. Kemudian akan dilakukan pengujian keakuratan dengan tiga metode. Hasil dari pengujian didapatkan seperti pada Tabel 4.

Hasil Prediksi dengan Data Uji

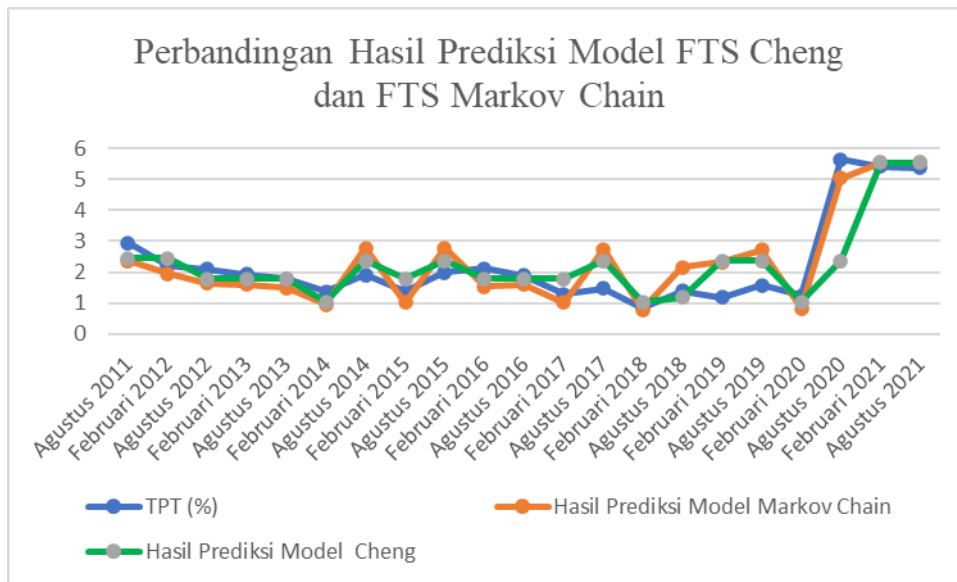
Setelah melakukan perhitungan pada data latih, selanjutnya dengan sisa data yang ada, yakni sebanyak 22 data, akan digunakan untuk perhitungan pada data uji. Masih sama dengan langkah yang sudah dipaparkan, Tabel 5 menunjukkan hasil yang didapatkan.

Tabel 5. Hasil prediksi data uji

t	Tahun	TPT (%)	Hasil Prediksi FTS Cheng	Hasil Prediksi FTS Markov Chain
1	Februari 2011	2,86		
2	Agustus 2011	2,95	2,633	2,368
3	Februari 2012	2,2	2,674	1,954
4	Agustus 2012	2,1	1,967	1,648
5	Februari 2013	1,92	1,922	1,593
6	Agustus 2013	1,79	1,841	1,493
7	Februari 2014	1,37	1,375	0,962
8	Agustus 2014	1,9	1,921	2,776
9	Februari 2015	1,37	1,832	1,023
10	Agustus 2015	1,99	1,921	2,776
11	Februari 2016	2,12	1,873	1,531
12	Agustus 2016	1,89	1,931	1,604
13	Februari 2017	1,28	1,828	1,018
14	Agustus 2017	1,48	1,880	2,746

t	Tahun	TPT (%)	Hasil Prediksi FTS Cheng	Hasil Prediksi FTS Markov Chain
15	Februari 2018	0,86	1,235	0,790
16	Agustus 2018	1,4	1,040	2,148
17	Februari 2019	1,19	1,934	2,328
18	Agustus 2019	1,57	1,840	2,716
19	Februari 2020	1,25	1,276	0,840
20	Agustus 2020	5,63	1,867	5,028
21	Februari 2021	5,42	5,581	5,542
22	Agustus 2021	5,37	5,487	5,542

Hasil pada Tabel 5 dapat divisualisasikan seperti pada Gambar 1 berikut.



Gambar 1. Grafik perbandingan hasil prediksi

Tabel 6. Perbandingan akurasi hasil prediksi pada data uji

Metode	MAPE (%)	RSME	Confusion Matrix		
			Akurasi (%)	Presisi (%)	Recall (%)
FTS Cheng	18,43	0,88	61,90	41,22	44,35
FTS Markov Chain	31,19	0,63	61,90	49,17	48,75

PEMBAHASAN

Berdasarkan Tabel 6, model FTS Cheng memiliki nilai MAPE sebesar 18,43% masuk dalam kriteria baik dengan akurasi 81,57%. Sedangkan, model FTS Markov Chain memiliki nilai MAPE sebesar 31,19% masuk dalam kriteria cukup dengan akurasi hanya 68,81%. Untuk RSME, model FTS Markov Chain lebih baik karena memiliki nilai yang lebih kecil dibandingkan dengan model FTS Cheng. Kemudian, jika berdasarkan *confusion matrix*, terlihat bahwa secara akurasi kedua metode sama. Namun, jika dilihat dari *presisi* dan *recall*, model FTS Markov Chain lebih baik dibandingkan model FTS Cheng. Ini disebabkan karena fuzifikasi data aktual dengan data hasil prediksi lebih mendekati dengan menggunakan model FTS Markov Chain. Sedangkan untuk *error* rata-rata mutlaknya lebih besar model FTS Cheng karena perbedaan dalam distribusi frekuensi dan banyaknya kelas interval yang dibentuk.

SIMPULAN

Kedua model memiliki keunggulannya masing-masing dalam prediksi tingkat pengangguran terbuka di Bali. Model *Fuzzy Time Series Markov Chain* keunggulannya yaitu fuzzifikasi hasil prediksi mendekati hasil data aktual. Sedangkan, untuk model *Fuzzy Time Series Cheng* keunggulannya yaitu persentase *error* rata-ratanya yang relatif kecil. Secara keseluruhan, dalam penelitian ini, akurasi model *Fuzzy Time Series Markov Chain* lebih baik dibandingkan dengan model *Fuzzy Time Series Cheng* di dua metode pengujian keakuratan yaitu di RMSE dan *Confusion Matrix*. Hal ini disebabkan karena perbedaan pembagian kelas serta perhitungan yang berbeda.

UCAPAN TERIMA KASIH

Terima kasih kepada pembimbing, staf dosen, sahabat-sahabat, dan keluarga serta semua pihak yang terlibat dalam penyelesaian artikel ini yang tidak bisa saya sebutkan satu persatu.

DAFTAR PUSTAKA

- BPS. (2021). *Tingkat Pengangguran Terbuka 2019-2020*. Badan Pusat Statistik. [https://sirusa.bps.go.id/sirusa/index.php/indikator/44#:~:text=Tingkat Pengangguran Terbuka %28TPT%29 Nama Indikator,ini ju ...](https://sirusa.bps.go.id/sirusa/index.php/indikator/44#:~:text=Tingkat%20Pengangguran%20TPT%29%20Nama%20Indikator,ini%20ju...) 2 more rows
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Cheng, C., Chen, T., Teoh, H., & Chiang, C. (2008). Fuzzy time-series based on adaptive expectation model for TAIEX forecasting. *Expert Systems with Applications*, 34(2), 1126–1132. <https://doi.org/10.1016/j.eswa.2006.12.021>
- Fauziah, L., Devianto, D., & Maiyastri, M. (2019). Peramalan beban listrik jangka menengah di wilayah teluk kuantan dengan metode fuzzy time series Cheng. *Jurnal Matematika UNAND*, 8(2), 84. <https://doi.org/10.25077/jmu.8.2.84-92.2019>
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: an overview. *A White Paper*, 1–17.
- Habibi, R., & Suryansah, A. (2020). *Aplikasi prediksi jumlah kebutuhan perusahaan* (1st ed.). Kreatif Industri Nusantara.
- Bramer, M. (2007). *Principles of Data Mining*. Springer London. <https://doi.org/10.1007/978-1-84628-766-4>
- Muhammad, P. H. (2022). *Perbandingan metode fuzzy time series markov chain dan fuzzy time series cheng dalam meramalkan nilai tukar rupiah terhadap dolar Amerika Serikat (AS)*. Universitas Andalas.
- Mustika, L. N. (2021). *Perbandingan metode fuzzy time series Cheng dan Markov Chain pada peramalan nilai tukar petani (ntp) di Indonesia*. Universitas Islam Negeri Maulana Malik Ibrahim.
- Noviani, N. (2021). *Perbandingan metode fuzzy time series Markov Chain dan fuzzy time series Cheng : studi kasus rata-rata harga beras*. Universitas Islam Negeri Maulana Malik Ibrahim.
- Prasetyo, N. E., & Rakhmadian, M. (2019). *EKONOMI INDONESIA: Wujud Internalisasi Nilai-Nilai Keindonesiaan* (1st ed.). Media Nusa Creative.
- Saputra, B. D. (2019). A fuzzy time series-Markov Chain model to forecast fish farming product. *Kursor*, 9(4). <https://doi.org/10.28961/kursor.v9i4.167>
- Singh, S. R. (2007). A simple method of forecasting based on fuzzy time series. *Applied Mathematics and Computation*, 186(1), 330–339. <https://doi.org/10.1016/j.amc.2006.07.128>
- Song, Q., & Chissom, B. S. (1993). Fuzzy time series and its models. *Fuzzy Sets and Systems*, 54(3), 269–277. [https://doi.org/10.1016/0165-0114\(93\)90372-0](https://doi.org/10.1016/0165-0114(93)90372-0)
- Sumartini, S., Nor Hayati, M., & Sri Wahyuningsih. (2017). Peramalan Menggunakan Metode Fuzzy Time Series Cheng Forecasting Using Fuzzy Time Series Cheng Method. *Jurnal EKSPONENSIAL*, 8(1), 51–56. <http://jurnal.fmipa.unmul.ac.id/index.php/exponensial/article/view/75/45>

- Tsaur, R.-C. (2012). A fuzzy time series-Markov Chain model with an application to forecast the exchange rate between the Taiwan and US dollar. *International Journal of Innovative Computing, Information, and Control*, 8(7 (B)), 4931–4942.
- Tsaur, R.-C., & Kuo, T.-C. (2011). The adaptive fuzzy time series model with an application to Taiwan's tourism demand. *Expert Systems with Applications*, 38(8), 9164–9171. <https://doi.org/10.1016/j.eswa.2011.01.059>