



## **Karakteristik Rantai Markov Pada Data Curah Hujan Bulanan Stasiun Djalaluddin**

*(Characteristics Of Markov Chain in Monthly Rainfall Data Station Djalaluddin)*

**Salmun K. Nasib<sup>1\*</sup>, Nurwan<sup>2</sup>, Eka Dicky D. Yanuari<sup>3</sup>, Tedy Machmud<sup>4</sup>**

<sup>1,3</sup> Statistika, MIPA, Universitas Negeri Gorontalo – Bone Bolango, Gorontalo, Indonesia

<sup>2</sup> Matematika, MIPA, Universitas Negeri Gorontalo – Bone Bolango, Gorontalo, Indonesia

<sup>4</sup> Pend. Matematika, MIPA, Universitas Negeri Gorontalo – Bone Bolango, Gorontalo, Indonesia

\*[salmun@ung.ac.id](mailto:salmun@ung.ac.id)

### **Abstrak**

Penelitian ini bertujuan untuk menganalisis karakteristik model rantai Markov pada data curah hujan bulanan. Data curah hujan bulanan dibagi dalam tiga *state* yaitu kering, lembab, dan basah. Sebagian besar data terkategori pada *state* 3 yaitu kondisi basah sebesar 54,41%. Berdasarkan hasil evaluasi data curah hujan di Stasiun Djalaluddin, memiliki curah hujan yang cukup tinggi dengan presentase diatas 50%. Peluang transisi tertinggi adalah  $P_{33}$  sebesar 61,9% dimana peluang transisi dari kondisi basah kembali ke kondisi basah lebih besar daripada peluang menuju kondisi kering atau lembab. Karakteristik rantai Markov data curah hujan bulanan menunjukkan kondisi yang tidak stabil dan kecilnya peluang transisi untuk berpindah ke kondisi lainnya.

**Kata kunci:** *Curah Hujan, Rantai Markov, Klasifikasi State*

### **Abstract**

*This research aims to to analyze the characteristics of the Markov chain model on monthly rainfall data. Monthly rainfall data is divided into three states, namely dry, moist, and wet. Most of the data are categorized in state 3, namely wet conditions of 54.41%. Based on the results of the evaluation of rainfall data at Djalaluddin Station, it has a fairly high rainfall with a percentage above 50%. The highest probability of transition is  $P_{33}$  of 61.9% where the probability of transition from wet conditions back to wet conditions is greater than the opportunity to dry or moist conditions. Markov chain characteristics of monthly rainfall data indicate unstable conditions and small transition opportunities to move to other conditions.*

**Keywords:** *Rainfall, Markov Chain, State Classification*

**Cara mengutip dengan APA 6 style:** Nasib, S.K., Nurwan, N., Yanuari, E. D. D. & Machmud, T. (2022). Karakteristik Rantai Markov Pada Data Curah Hujan Bulanan Stasiun Djalaludin. *JMPM: Jurnal Matematika dan Pendidikan Matematika*, 7(1), 1-4. <https://dx.doi.org/10.26594/jmpm.v7i2.2654>.

## PENDAHULUAN

Curah hujan merupakan salah satu unsur iklim yang berpengaruh terhadap kondisi lingkungan dan hampir pada setiap kegiatan yang dilakukan manusia, karena berkaitan dengan kuantitas dan intensitasnya (Back & Miguel, 2017). Selain itu, curah hujan memiliki variabilitas dari segi ruang dan waktu, karena curah hujan memiliki keragaman pada setiap wilayah. Prediksi terhadap curah hujan sangatlah penting dilakukan untuk mengetahui keadaan curah hujan di masa yang akan datang (Aprianto & Puspitasari, 2020). Curah hujan yang turun ke permukaan bumi setiap harinya tidak selalu sama, hal ini disebabkan oleh kondisi ketidakpastian curah hujan yang dikarenakan perubahan dari satu keadaan ke keadaan yang lain. Berdasarkan jumlah curah hujannya, Indonesia sebagai negara yang beriklim tropis dikenal hanya memiliki dua musim dalam satu tahun, yaitu musim kemarau dan musim hujan.

Provinsi Gorontalo merupakan salah satu daerah di Indonesia yang memiliki topografi kompleks yang berpengaruh besar pada variasi hujan. Hal tersebut membuat cuaca sulit diprediksi dan menimbulkan berbagai masalah seperti banjir dan kekeringan. Kabupaten Gorontalo merupakan salah satu wilayah di Provinsi Gorontalo yang sering terkena dampak banjir dan kekeringan. Tahun 2020 Kabupaten Gorontalo telah mengalami dua kali musibah banjir, yaitu pada bulan Maret dan bulan Agustus. Kekeringan juga terjadi pada tahun 2014-2015 yang dipicu oleh fenomena El Nino berdampak langsung pada sektor pertanian dan sumber daya air (Koem et al., 2022; Koem & Rusiyah, 2017, 2018). Oleh karena itu, perlu dilakukan upaya yaitu dengan melihat gambaran perpindahan kondisi curah hujan yang selalu berubah terhadap waktu.

Pendekatan yang tepat dalam menganalisis perubahan variabel menurut fungsi waktunya adalah proses stokastik, yang merupakan proses yang bergantung pada waktu (*time-dependent*). Model stokastik dipilih karena dapat meningkatkan kualitas prakiraan curah hujan pada daerah yang pola curah hujannya dipengaruhi topografi lokalnya. Rantai Markov adalah model stokastik waktu diskrit yang didefinisikan pada ruang keadaan (*state*), dilengkapi dengan probabilitas transisi dari keadaan ke keadaan lain pada tahap waktu berikutnya (Nop et al., 2021). Dalam mengevaluasi karakteristik curah hujan menggunakan rantai Markov, dibutuhkan data hasil pengukuran curah hujan historis untuk mengukur karakteristik transisi antara hari basah dan kering (Yoo et al., 2016). Oleh karena itu, rantai Markov dapat diterapkan untuk membuat model dan mengamati transisi suatu kejadian.

Aplikasi rantai Markov dapat digunakan untuk mengevaluasi probabilitas untuk mengidentifikasi urutan minggu basah dan kering dengan menggunakan data curah hujan mingguan, sehingga dapat memberikan informasi mengenai daerah yang memiliki tingkat kerawanan kekeringan (Banik et al., 2002). Selain itu, studi mengenai pola curah hujan dengan menggunakan rantai Markov dapat mencerminkan lintasan runtun waktu curah hujan bulanan (Tetty et al., 2017). Penerapan metode rantai Markov untuk satu lokasi (*single location*) dapat dilakukan dengan mempertimbangkan variabel laten untuk memperkirakan dan memprediksi jumlah curah hujan dan kemungkinan periode kering (Sanso & Guenni, 1999). Berdasarkan kajian terdahulu, rantai Markov merupakan model yang tepat dalam menganalisis perpindahan kondisi curah hujan pada satu lokasi (*single location*) yaitu di stasiun Djalaluddin Kabupaten Gorontalo, sehingga

klasifikasi *state* rantai Markov digunakan dalam melihat gambaran kondisi curah hujan Stasiun Djalaluddin. Tujuan penelitian ini adalah untuk menganalisis karakteristik model Rantai Markov pada data curah hujan bulanan stasiun Djalaluddin.

## METODE PENELITIAN

Penelitian ini menggunakan data curah hujan bulanan tahun 1985-2020 yang diperoleh dari Stasiun Djalaluddin BMKG Gorontalo. Penelitian ini menekan pada penerapan rantai Markov pada tiga keadaan (*state*) yaitu kering, lembab, dan basah. Penerapan rantai Markov pada tiga *state* tersebut bertujuan untuk menghitung probabilitas transisi antar *state* (Jale et al., 2019). Langkah analisis yang akan dilakukan dalam menganalisis karakteristik curah hujan bulanan adalah sebagai berikut:

1. Melakukan statistika deskriptif untuk mengetahui gambaran awal data, melihat pola penyebaran curah hujan sebelum dilakukan analisis lebih lanjut.
2. Mengkategorikan data berdasarkan pembagian *state*. *State* atau ruang keadaan dibagi menjadi tiga yaitu *state* 1 (kondisi kering dengan curah hujan bulanan kurang dari 60 mm), *state* 2 (kondisi lembab dengan curah hujan bulanan sebesar 60-100 mm), dan *state* 3 (kondisi basah dengan curah hujan bulanan lebih dari 100 mm).
3. Menghitung matriks peluang transisi dengan melihat data yang telah dikategorikan berdasarkan *state*. Matriks peluang transisi dibentuk dan akan digunakan untuk melihat perpindahan-perpindahan yang terjadi antar *state* yang kemudian diklasifikasikan model perpindahannya.
4. Mengklasifikasikan model rantai Markov yang didapat dari matriks peluang transisi, kemudian dapat dilihat bagaimana kondisi curah hujan bulanan dengan melihat perpindahan antar *state*-nya.

## HASIL DAN PEMBAHASAN

### Statistika Deskriptif


Data yang dianalisis merupakan data curah hujan bulanan yang diperoleh dari Stasiun Djalaluddin Gorontalo dari bulan Januari 1985 sampai Desember 2020, dengan cakupan wilayah dilihat dari titik pengamatan seluas 100-250 km<sup>2</sup>.

**Tabel 1. Statistika Deskriptif**

N	Mean	Varians	Std. Dev.	Min	Max
432	118,88	6650,4	81,55	0	411,8

Pada Tabel 1, kolom N menyatakan jumlah atau banyaknya data yaitu sebanyak 432 bulan. Selanjutnya pada kolom *mean* mengartikan bahwa rata-rata besar curah hujan bulanan sebesar 118,88 mm. Sedangkan nilai varians sebesar 6650,4 berarti bahwa data memiliki nilai keragaman yang tinggi dan standar deviasi sebesar 81,55 mengindikasikan bahwa titik data sangat tersebar di sekitar rata-rata. Kondisi curah hujan terendah adalah sebesar 0 mm dan tertinggi sebesar 411,8 mm. Dari hasil statistika deskriptif tersebut diperoleh gambaran bahwa curah hujan di

wilayah pengukuran Stasiun Djalaluddin Gorontalo cenderung tidak menentu dan sulit diprediksi karena memiliki keragaman dan penyebaran yang tinggi. Hal tersebut juga dapat dilihat pada diagram garis pada Gambar 1.



**Gambar 1. Pola Curah Hujan Stasiun Djalaluddin Tahun 1985-2020**

**Kategorisasi Data Berdasarkan Pembagian *State***

Dalam penelitian ini ruang keadaan (*state*) dibagi menjadi tiga yaitu *state* 1 (kering), *state* 2 (lembab), dan *state* 3 (basah). Pembagian ini berdasarkan kategori curah hujan bulanan menggunakan klasifikasi *Schmidt-Ferguson* yaitu bulan kering, bulan lembab, dan bulan basah (Handoko, 2017). Tersajikan dalam Tabel 2, kondisi kering adalah kondisi dimana curah hujan kurang dari 60 mm dan didefinisikan sebagai *state* 1. *State* 2 adalah kondisi lembab dengan curah hujan antara 60 mm sampai dengan 100 mm, sedangkan curah hujan yang lebih dari 100 mm didefinisikan sebagai *state* 3.

**Tabel 2. Kategori *State***

<i>State</i>	Kategori	Intensitas Curah Hujan Bulanan (mm)
1	Kering	<60
2	Lembab	60-100
3	Basah	>100

Berdasarkan pembagian *state* tersebut, maka dapat dihitung jumlah bulan yang terdapat pada setiap *state*.

**Tabel 3. Pembagian *State***

<i>State</i>	Kategori	Jumlah Bulan	Presentase
1	Kering	111	25,69%

2	Lembab	86	19,90%
3	Basah	235	54,41%

Tabel 3 menunjukkan bahwa jumlah bulan beserta persentasenya yang telah dibagi pada setiap *state*. Terlihat bahwa sebagian besar data terkategori pada *state* 3 yaitu kondisi basah dengan jumlah bulan sebanyak 235 bulan dan persentase sebesar 54,41%. Artinya di wilayah pengukuran Stasiun Djalaluddin Gorontalo sebagian besar mengalami kondisi basah pada rentang waktu tahun 1985 sampai dengan tahun 2020. Sedangkan sebanyak 111 bulan adalah kondisi kering atau sebesar 25,69%, dan kondisi lembab menjadi yang paling sedikit dengan 86 bulan atau sebesar 19,90%. Berdasarkan pembagian tersebut, dapat dilihat bahwa daerah di wilayah pengukuran Stasiun Djalaluddin Gorontalo merupakan daerah yang memiliki curah hujan yang cukup tinggi dengan persentase diatas 50%.

**Matriks Peluang Transisi**

Setelah melakukan klasifikasi data berdasarkan *state*, dibuat matriks peluang transisi yang diperoleh dari perhitungan jumlah transisi setiap *state*. Sebelum menghitung peluang transisinya, ditentukan terlebih dahulu frekuensi transisi dari *state* *i* ke *state* *j*. Setelah menentukan frekuensi transisi dari *state* *i* ke *state* *j*, maka dapat dibentuk matriks peluang transisinya.


**Tabel 4. Peluang Transisi State *i* ke State *j***

State ( <i>i</i> )	State ( <i>j</i> )		
	1	2	3
1	0,4513274	0,1592920	0,3893805
2	0,2619048	0,2023810	0,5357143
3	0,1709402	0,2094017	0,6196581

Pada tabel 4 dapat dilihat bahwa matriks peluang transisi curah hujan bulanan Stasiun Djalaluddin Gorontalo menunjukkan peluang transisi tertinggi adalah  $P_{33}$  atau peluang transisi dari kondisi basah ke kondisi basah kembali lebih besar daripada peluang menuju kondisi kering atau lembab yaitu sebesar 61,9%. Peluang tersebut mengindikasikan bahwa curah hujan bulanan pada wilayah pengukuran Stasiun Djalaluddin pada saat kondisi curah hujan tinggi akan berpeluang paling besar untuk kembali ke kondisi curah hujan yang tinggi pada bulan selanjutnya.

**Klasifikasi State Model Rantai Markov**

Klasifikasi *state* rantai Markov menurut karakteristiknya dapat menggambarkan kondisi curah hujan bulanan yang terjadi di wilayah pengukuran Stasiun Djalaluddin. Perpindahan atau transisi yang terjadi antara *state* 1 (basah), *state* 2 (lembab), dan *state* 3 (kering). Pada Gambar 2, digambarkan klasifikasi model rantai Markov berdasarkan pada peluang transisi *state* yaitu peluang perpindahan dari *state* *i* ke *state* *i* maupun dari *state* *i* ke *state* *j* ataupun sebaliknya. Selanjutnya klasifikasi *state* model rantai Markov yang dibahas dalam penelitian ini yaitu *Accessible*, *Irreducible*, *Recurrent*, dan *Absorbing State*.



Gambar 2. Transisi State

### Accessible

State yang dapat dicapai atau *accessible* yaitu jika  $P_{ij}^n > 0$ , dari gambar 2 dapat dilihat state yang memenuhi klasifikasi tersebut adalah sebagai berikut:

1. State 1 *accessible* dari state 2, dengan  $P_{12} = 0,1592920$  artinya terdapat transisi dari kondisi kering ke kondisi lembab dengan peluang transisi sebesar 15,9%.
2. State 1 *accessible* dari state 3, dengan  $P_{13} = 0,3893805$  artinya terdapat transisi dari kondisi kering ke kondisi basah dengan peluang transisi sebesar 38,9%.
3. State 2 *accessible* dari state 1, dengan  $P_{21} = 0,2619048$  artinya terdapat transisi dari kondisi lembab ke kondisi kering dengan peluang transisi sebesar 26,2%.
4. State 2 *accessible* dari state 3, dengan  $P_{23} = 0,5357143$  artinya terdapat transisi dari kondisi lembab ke kondisi basah dengan peluang transisi sebesar 53,6%.
5. State 3 *accessible* dari state 1, dengan  $P_{31} = 0,1709402$  artinya terdapat transisi dari kondisi basah ke kondisi kering dengan peluang transisi sebesar 17,1%.
6. State 3 *accessible* dari state 2, dengan  $P_{32} = 0,2094017$  artinya terdapat transisi dari kondisi basah ke kondisi lembab dengan peluang transisi sebesar 20,9%.

### Irreducible

*Irreducible* terjadi jika semua state berkomunikasi, artinya jika state  $i$  berkomunikasi dengan state  $j$ , maka state  $j$  juga berkomunikasi dengan state  $i$ . State yang saling berkomunikasi adalah sebagai berikut:

1. State 1 saling berkomunikasi dengan state 2. Artinya terdapat transisi dari kondisi kering ke kondisi lembab, dan sebaliknya terdapat juga transisi dari kondisi lembab ke kondisi kering.

2. *State* 1 saling berkomunikasi dengan *state* 3. Artinya terdapat transisi dari kondisi kering ke kondisi basah, dan sebaliknya terdapat juga transisi dari kondisi basah ke kondisi kering.
3. *State* 2 saling berkomunikasi dengan *state* 3. Artinya terdapat transisi dari kondisi lembab ke kondisi basah, dan sebaliknya terdapat juga transisi dari kondisi basah ke kondisi lembab.

Karena semua *state* saling berkomunikasi, maka hanya ada satu kelas komunikasi yaitu  $\{1,2,3\}$  semua *state* berkomunikasi, maka rantai Markov dikatakan *irreducible*. Dari karakteristik ini, dapat dilihat kondisi curah hujan yang tidak stabil. Meskipun semua *state* saling berkomunikasi, tetapi peluang transisi yang terjadi menunjukkan tidak stabilnya kondisi curah hujan. Seperti perpindahan dari kondisi kering menuju kondisi lembab ataupun sebaliknya memiliki peluang transisi yang kecil untuk terjadi. Sedangkan peluang transisi dari kondisi lembab menuju kondisi basah lebih besar daripada kondisi basah kembali ke kondisi lembab.

### **Recurrent**

Berdasarkan karakteristik sebelumnya (*irreducible*) dimana semua *state* saling berkomunikasi, maka dapat dikatakan bahwa *state* 1, 2, dan 3 adalah *reccurent*. Artinya jika suatu proses telah memasuki *state*  $i$  maka akan kembali lagi ke *state*  $i$ .

### **Absorbing State**

Suatu *state* dikatakan absorbing (penyerap) jika  $P_{ii} = 1$ , sehingga dari gambar 2 dapat dilihat bahwa tidak ada *state* yang *absorbing*. Artinya setelah memasuki *state*  $i$ , ada peluang bahwa proses akan meninggalkan *state*  $i$ .

1. *State* 1 tidak *absorbing* karena  $P_{11} = 0,4513274$  artinya terdapat transisi setelah memasuki kondisi kering akan menuju ke kondisi lainnya.
2. *State* 2 tidak *absorbing* karena  $P_{22} = 0,2023810$  artinya terdapat transisi setelah memasuki kondisi lembab akan menuju ke kondisi lainnya.
3. *State* 3 tidak *absorbing* karena  $P_{33} = 0,6196581$  artinya terdapat transisi setelah memasuki kondisi basah akan menuju ke kondisi lainnya.

Dari karakteristik ini dapat dilihat bahwa peluang transisi cukup tinggi untuk kembali lagi dari suatu kondisi ke kondisi tersebut. Seperti pada  $P_{11}$  dan  $P_{33}$  masing-masing sebesar 45% dan 61,9% yang cukup besar mengartikan bahwa saat kondisi kering ataupun basah, peluang untuk menuju kondisi lain lebih kecil dari kembali lagi ke kondisi tersebut. Oleh karena itu, kekeringan dan banjir masih sering terjadi pada sekitar wilayah pengukuran Stasiun Djalaluddin Gorontalo. Curah hujan yang rendah berlangsung dalam waktu yang cukup lama dan sulit untuk berpindah ke kondisi curah hujan yang lebih tinggi, karena sulitnya perpindahan dari kondisi kering menuju kondisi basah ataupun lembab maka dapat memicu bencana kekeringan terjadi. Sedangkan curah hujan tinggi yang berlangsung dalam waktu yang cukup lama dan sulit untuk berpindah ke kondisi curah hujan yang lebih rendah, dapat memicu terjadinya banjir karena sulitnya perpindahan dari kondisi basah menuju kondisi kering maupun lembab.

---

## KESIMPULAN DAN SARAN

Karakteristik rantai Markov data curah hujan bulanan Stasiun Djalaluddin Gorontalo menunjukkan bahwa kondisi curah hujan yang tidak stabil dan kecilnya peluang transisi untuk berpindah ke kondisi lainnya. Saran untuk penelitian selanjutnya yaitu dapat menggunakan data atau studi kasus di wilayah yang lain dan periode waktu yang lebih panjang serta menambah pembagian *state* untuk mendapatkan perpindahan hujan yang lebih variatif.

## UCAPAN TERIMA KASIH

Ucapan terima kasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat Universitas Negeri Gorontalo atas dukungan spiritual dan materialnya sehingga penelitian ini dapat berjalan dengan lancar.

## DAFTAR RUJUKAN

- Aprianto, R., & Puspitasari, P. A. D. (2020). Prediksi curah hujan bulanan tahun 2020 kabupaten Sumbawa menggunakan Artificial Neural Network (ANN) Back Propagation. *Prosiding Seminar Nasional IPPeMas*, 1(1), 622–628.
- Back, Á. J., & Miguel, L. P. (2017). Analysis of the stochastic model of the Markov chain on daily rainfall occurrence in the state of Santa Catarina, Brazil. *Management of Environmental Quality: An International Journal*, 28(1), 2–16. <https://doi.org/10.1108/MEQ-07-2015-0135>
- Banik, P., Mandal, A., & Rahman, M. S. (2002). Markov chain analysis of weekly rainfall data in determining drought-proneness. *Discrete Dynamics in Nature and Society*, 7(4), 231–239. <https://doi.org/10.1155/S1026022602000262>
- Jale, J. da S., Xavier Júnior, S. F. A., Xavier, É. F. M., Stošić, T., Stošić, B., & Ferreira, T. A. E. (2019). Application of Markov chain on daily rainfall data in Paraíba-Brazil from 1995-2015. *Acta Scientiarum - Technology*, 41(1). <https://doi.org/10.4025/actascitechnol.v41i1.37186>
- Koem, S., Lahay, R. J., & Nasib, S. K. (2022). The sensitivity of meteorological drought index towards El Nino-Southern Oscillation. *IOP Conference Series: Earth and Environmental Science*, 1089(1), 012005. <https://doi.org/10.1088/1755-1315/1089/1/012005>
- Koem, S., & Rusiyah. (2017). Monitoring of drought events in Gorontalo Regency. *IOP Conference Series: Earth and Environmental Science*, 98, 012053. <https://doi.org/10.1088/1755-1315/98/1/012053>
- Koem, S., & Rusiyah, R. (2018). Karakteristik spasiotemporal kekeringan meteorologi di kabupaten Gorontalo tahun 1981-2016. *Jurnal Pengelolaan Sumberdaya Alam Dan Lingkungan*, 8(3), 355–364. <https://doi.org/10.29244/jpsl.8.3.355-364>
- Nop, C., Fadhil, R. M., & Unami, K. (2021). A multi-state Markov Chain Model for rainfall to be used in optimal operation of rainwater harvesting systems. *Journal of Cleaner Production*, 285, 124912. <https://doi.org/10.1016/j.jclepro.2020.124912>
- Sanso, B., & Guenni, L. (1999). A stochastic model for tropical rainfall at a single location. *Journal of Hydrology*, 214, 64–73.
- Tetty, M., Oduro, F. T., Adedia, D., & Abaye, D. A. (2017). Markov chain analysis



of the rainfall patterns of five geographical locations in the south eastern coast of Ghana. *Earth Perspectives*, 4(1). <https://doi.org/10.1186/s40322-017-0042-6>

Yoo, C., Lee, J., & Ro, Y. (2016). Markov chain decomposition of monthly rainfall into daily rainfall: evaluation of climate change impact. *Advances in Meteorology*, 2016. <https://doi.org/10.1155/2016/7957490>