

MODELAGEM COMPUTACIONAL: UTILIZANDO CADEIAS DE MARKOV PARA PREDIZER DADOS CLIMÁTICOS

COMPUTATIONAL MODELING: USING MARKOV CHAINS TO PREDICT CLIMATE DATA

Bruno Oliveira Cardoso 1
Jéssica Figuera Oliveira 2
Elaine Pereira Garrido 3
Marcos Batista Figueredo 4
Maria Dolores Ribeiro Orge 5
José Roberto de Araújo Fontoura 6

Resumo: Na região Tropical, a precipitação pluvial desempenha um papel de extrema importância como fenômeno meteorológico, pois exerce influência sobre diversos processos em áreas variadas, como agricultura e floresta. O objetivo deste trabalho está em estimar a variabilidade da temperatura e umidade em Salvador (Ba), identificando os dias que são outliers. Considerou-se, para esta classificação, de alcance descritivo com abordagem quantitativa. Um estudo de clima utilizando Cadeias de Markov, cujo propósito é analisar a umidade e temperatura em uma pequena área de 20m². Criando assim, um conjunto de dados com um total de 606 dados de umidade e temperatura entre os dias 19 a 24 de junho de 2023 na cidade de Salvador-Ba. A pesquisa evidenciou que a matriz de transição da Temperatura tende a aumentar as probabilidades para que ocorram entre (28 a 30+) e que na umidade terá uma maior probabilidade de estar abaixo de 70% de umidade.

Palavras-chave: Cadeias de Markov. Dados climáticos. Modelagem. Python.

Abstract: In the Tropical region, rainfall plays an extremely important role as a meteorological phenomenon, as it influences several processes in different areas, such as agriculture and forestry. The objective of this work is to estimate the variability of temperature and humidity in Salvador (Ba), identifying the days that are outliers. For this classification, it was considered descriptive in scope with a quantitative approach. A climate study using Markov Chains, whose purpose is to analyze humidity and temperature in a small area of 20m². Thus, creating a data set with a total of 606 humidity and temperature data between June 19th and 24th, 2023 in the city of Salvador-Ba. The research showed that the Temperature transition matrix tends to increase the probabilities of occurrences (28 to 30+) and that in humidity there will be a greater probability of being below 70% humidity.

Keywords: Markov Chains. Climate Data. Modeling. Python.

1 - Mestrando em Modelagem e Simulação de Biosistemas. Instituição: Universidade do Estado da Bahia (UNEB). Lattes: <http://lattes.cnpq.br/5116130558948433>. ORCID: <https://orcid.org/0009-0006-2377-9127>. E-mail: cardosocontabil.bahia@gmail.com

2 - Mestranda em Modelagem e Simulação de Biosistemas. Instituição: Universidade do Estado da Bahia (UNEB). Lattes: <http://lattes.cnpq.br/5116130558948433>. ORCID: 0000-0002-1217-9146. E-mail: ma.jessicafiguera@gmail.com

3 - Graduanda em Engenharia Sanitária e Ambiental. Instituição: Universidade do Estado da Bahia (UNEB). Lattes: <http://lattes.cnpq.br/4321559283202802>. ORCID: 0009-0008-1722-1404. E-mail: elainepegarrido@gmail.com

4 - Doutor em Modelagem computacional e Tecnologia Industrial. Instituição: Faculdade de Tecnologia SENAI CIMATEC (FTSC). Lattes: <http://lattes.cnpq.br/6235735011979354>. ORCID: <https://orcid.org/0000-0002-8193-5419> E-mail: mbfigueredo@uneb.br

5 - Doutora em Ecología y Medio Ambiente. Instituição: Universidad Complutense de Madrid (UCM). Lattes: <http://lattes.cnpq.br/7039932305357538>. ORCID: <https://orcid.org/0000-0002-0018-9574>. E-mail: mdrorge@uneb.br

6 - Doutor em Difusão do Conhecimento. Instituição: Universidade Federal da Bahia (UFBA). Lattes: <http://lattes.cnpq.br/7410531451699564>. ORCID: <https://orcid.org/0000-0002-9703-835X>. E-mail: jfontoura@uneb.br

Introdução

Na região Tropical, a precipitação pluvial desempenha um papel de extrema importância como fenômeno meteorológico, pois exerce influência sobre diversos processos em áreas variadas, como agricultura e floresta. Especificamente na agricultura, a variabilidade das chuvas causa flutuações nos rendimentos agrícolas anuais (MOUSINHO *et al.*, 2006).

Para otimizar projetos com manejo de atividades agrícolas, é essencial determinar a distribuição das chuvas e estimar as probabilidades de ocorrência de dias secos e chuvosos. As conhecimentos desses aspectos contribui significativamente para a tomada de decisões sobre épocas de plantio, avaliação de riscos de escassez de água e dimensionamento e gerenciamento de sistemas de irrigação (KELLER FILHO, *et al.*, 2006; FERREIRA, 2012; MARCELINO *et al.*, 2012; BREINL *et al.*, 2013). A análise da frequência de dias secos e chuvosos e suas transições ao longo do ano pode ser melhor abordada através do uso da Cadeia de Markov (STERN *et al.*, 1982; AZEVEDO; LEITÃO, 1990; LENNARTSSON *et al.*, 2008).

O estudo de clima, os sensores de umidade e temperatura DHT22 desta pesquisa registram a entrada e após a aferição dessas informações, é possível verificar se as coletas de campo são viáveis ou não de serem realizadas naquele momento dada as probabilidades calculadas pelas Cadeias de Markov. Neste contexto, a fim de nortear pesquisadores locais que realizam este tipo de coleta, foi montado um protótipo utilizando um microcontrolador Arduino Uno 3, fazendo a escolha dos sensores climáticos básicos convenientes para estruturar as estações meteorológicas, além de servir de subsídio para eles elaborarem os próprios protótipos de forma simples e prática

Além disso, com a tecnologia da IoT, viabiliza-se a automação das estações meteorológicas, aprimorando a praticidade e confiabilidade nas aquisições dos dados (KODALI; MANDAL, 2016). Portanto, as vantagens deste protótipo são: a praticidade na obtenção dos dados; compacto e de fácil instalação. Cujas presentes pesquisas precípua na construção deste referido protótipo que abranja apenas os sensores de temperatura e umidade, combinados com as Cadeias de Markov que são definidas como um modelo matemático e que apenas a experiência atual poderia afetar o passo seguinte (BOLSON *et al.*, 2019).

Em função desse quadro climático volátil, esse trabalho tem o objetivo em estimar a variabilidade da temperatura e umidade em Salvador (BA), identificando os dias que são outliers. Para a predição dos valores futuros utilizarem os modelos de cadeia de Markov que têm sido amplamente utilizados em precipitação (JALE *et al.*, 2019; DE AMORIM *et al.*, 2019), velocidade do vento (SANTOS *et al.*, 2019).

Fundamentação teórica

Nos últimos anos, muitos estudos e diversas aplicações foram realizados sobre Cadeias de Markov nas condições climáticas, cuja proposta versa sobre a criação de estratégias para antecipação do clima. Neste sentido, este capítulo tem por finalidade a evidencição de pesquisas em ordem crescente, do período entre 2016 e 2020.

Pasqual, Liposki, Corso (2016), Aplicação de Cadeias de Markov para Determinação de Probabilidades de Estados Climáticos na Cidade de Caxias do Sul. Este artigo propôs o emprego deste método para previsão da variação de condições meteorológicas para alguns meses do ano de 2015 na cidade de Caxias do Sul. A partir dos resultados obtidos, verifica-se que a análise dos dados climáticos atuais utilizando as Cadeias de Markov para identificação das probabilidades de transição para uma determinada situação climática futura é válida, desde que sejam utilizados dados que atendam a precisão exigida pelo modelo.

Carvalho *et al.* (2017), Aplicação da Cadeias de Markov para Dias Secos e Chuvosos. O objetivo desse trabalho foi analisar a ocorrência de dias secos e chuvosos na região de Rio Largo–Alagoas, por meio da Cadeia de Markov. Dados diários de precipitação entre 1973 e 2008 foram utilizados. Aplicou-se a Cadeia de Markov, para identificar as probabilidades de ocorrências condicionais de dias secos e chuvosos. Maior ocorrência de dias secos e chuvosos

ocorreu de novembro a dezembro (94%) e junho a julho (84%), respectivamente. A Cadeia de Markov permitiu concluir que a transição entre dias secos e chuvosos é baixa ao longo do ano.

Minuzzi (2017), Aplicação da Cadeias de Markov para Previsão Mensal de Chuva em Santa Catarina Durante o El Niño Oscilação Sul. Foram utilizados dados mensais de chuva de setembro a abril do período de 1958 a 2013 de nove estações localizadas em diferentes regiões climáticas do Estado. A pesquisa dividiu nos seguintes estados: abaixo (-1), dentro (0) e acima (1) da climatologia. Os principais resultados mostram que durante o El Niño há um padrão mais definido das chuvas, resultando em previsões probabilísticas mais eficientes por meio das matrizes de transição, quando comparadas a anos de La Niña.

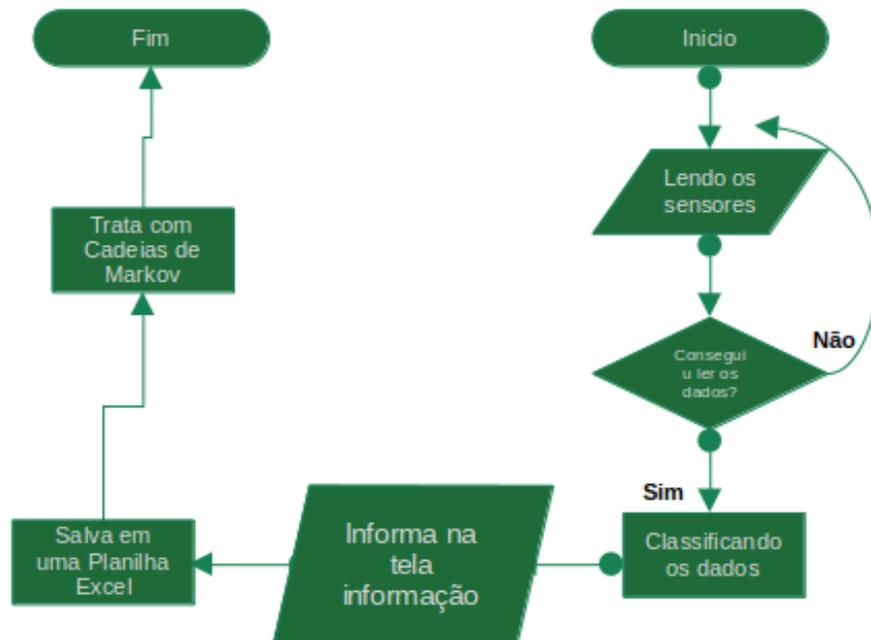
Matos *et. al* (2019), Aplicação de Cadeias de Markov na Avaliação da Transição do Clima na Cidade de São Paulo. A pesquisa utilizou as Cadeias de Markov para obter as probabilidades de estado estável de cada estação do ano. A base de dados contempla valores diários da temperatura no período de 20 anos (1998 a 2018), vindo do Banco de Dados Meteorológicos para Ensino e Pesquisa do Instituto Nacional de Meteorologia. Verifica-se que a probabilidade de aumento de temperatura para cidade de São Paulo em cada estação do ano varia entre 77% e 83%, evidenciando as probabilidades de aumento.

Grossi (2020), Cadeias de Markov aplicadas à definição de camadas litológicas para modelos numéricos de fluxo de águas subterrâneas. A pesquisa procura discutir as premissas as premissas utilizadas na definição do arcabouço geológico de uma simulação de fluxo. Cômputos finas dentre as repostas equiprováveis de 20 simulações MBDE, à crescentes incrementos de vazões de bombeamento, indicaram incrementos na eficácia da captação de partículas. Estimou-se que 100% das partículas devam ser captadas por uma barreira hidráulica mínima, mais eficaz, com vazão total de 96 m³/dia.

Como ficou evidenciado existem diversas pesquisas com aplicações de Cadeias de Markov e que a cada ano tem se utilizado em seus trabalhos para a criação de novos métodos para predizer o clima.

Modelo conceitual

Figura 1. Modelo Conceitual



Fonte: Autoral (2023).

Metodologia

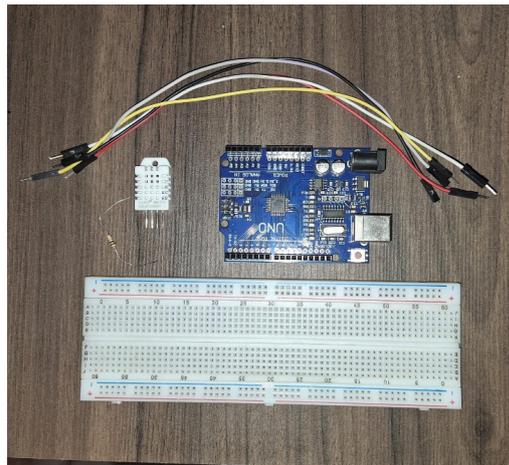
A realização deste trabalho se dá em fomentar benefícios em auxiliar no processo de criação de um protótipo de análise de clima. Com as informações obtidas do protótipo será realizado a modelagem com as cadeias de Markov que está pautado em verificar a frequência da movimentação histórica e assim criar uma matriz de transição para monitorar as próximas que ainda virão.

Considerou-se, para esta classificação, de alcance descritivo com abordagem quantitativa. Um estudo de clima utilizando Cadeias de Markov, cujo proposito é analisar a umidade e temperatura em uma pequena área de 20m². Esta pesquisa analisa os dados coletados como amostra os 606 dados que fundamenta este estudo.

Material Utilizado

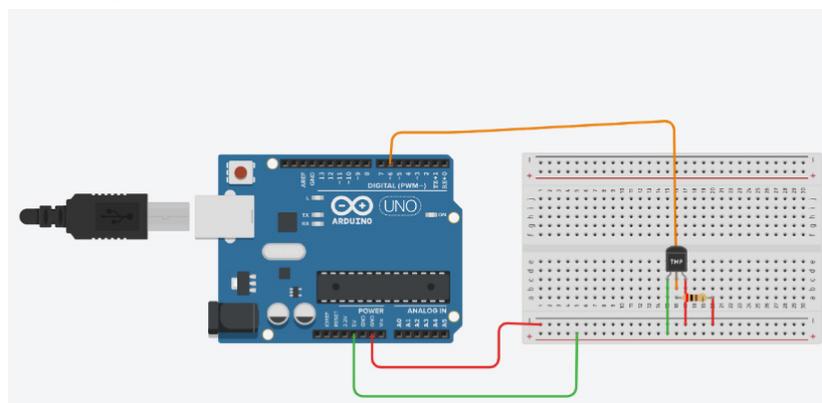
- 01 - Arduino UNO rev3
- 01 - Sensor de Umidade e Temperatura AM2302 DHT22
- 01 - Protoboard
- 05 - Jumpers
- 01 - Resistor 10kW

Figura 2. Material Utilizado



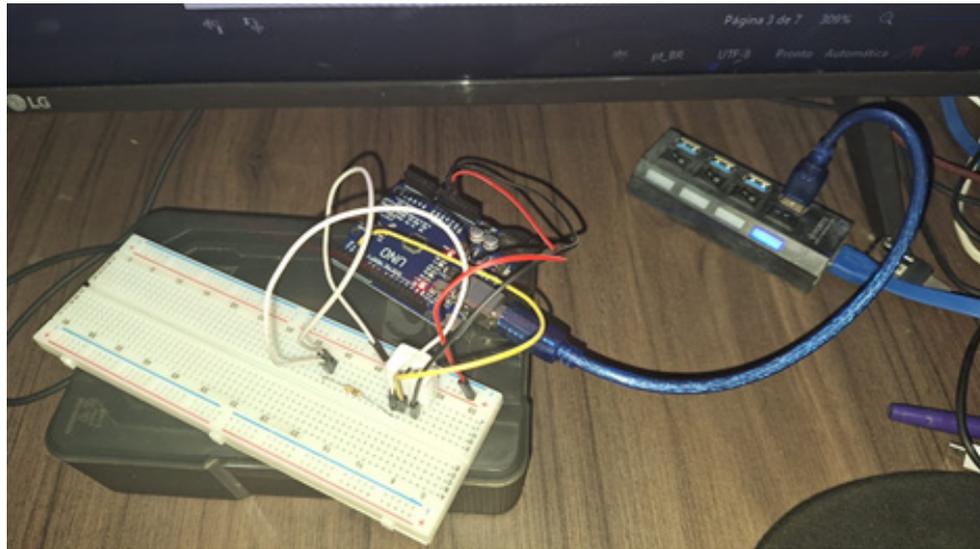
Fonte: Autoral (2023).

Figura 3. Esquema do Projeto



Fonte: Autoral (2023).

Figura 4. Projeto Pronto



Fonte: Autoral (2023)

Coleta de dados

A coleta de dados foi realizada com a utilização de um arduino uno 3 e um sensor de temperatura e umidade DHT22 em horários alternados para se obter diversas variáveis em relação ao clima. Criando assim, um conjunto de dados com um total de 606 dados de umidade e temperatura entre os dias 19 e 24 de junho de 2023 na cidade de Salvador-BA para o cálculo das probabilidades para as Cadeias de Markov utilizando a linguagem de programação em Python para calculos das matrizes e resoluções de Markov.

Resultados e discussão

Temperatura

Uma observação das mudanças de estado referente a temperatura, criados 8 diferentes estados de transição, sendo que a temperatura mais baixa registrada foi de 24°C e mais alta 33°C aproximadamente e nota-se que dentre todos os estados não foram encontrados nenhum do estado (30.0 – 31.0). Neste sentido, foi criado as faixas e sua matriz de transição conforme:

Tabela 1. Contagem de Transições para Calcular as Probabilidades da Temperatura

	[24.0 - 25.0]	[25.0 - 26.0]	[26.0 - 27.0]	[27.0 - 28.0]	[28.0 - 29.0]	[29.0 - 30.0]	[30.0 - 31.0]	[31.0 - 100.0]
[24.0 - 25.0]	25	0	1	0	0	0	0	0
[25.0 - 26.0]	0	47	2	0	0	0	0	0
[26.0 - 27.0]	0	0	175	1	0	3	0	0
[27.0 - 28.0]	0	1	0	100	2	0	0	0
[28.0 - 29.0]	1	0	0	2	97	1	0	0
[29.0 - 30.0]	0	0	1	0	2	92	0	1
[30.0 - 31.0]	0	0	0	0	0	0	0	0
[31.0 - 100.0]	0	0	0	0	0	0	0	51

Fonte: Autoral (2023)

Tabela 2. Matriz de Transição da Temperatura

	[24.0 - 25.0]	[25.0 - 26.0]	[26.0 - 27.0]	[27.0 - 28.0]	[28.0 - 29.0]	[29.0 - 30.0]	[30.0 - 31.0]	[31.0 - 100.0]
[24.0 - 25.0]	96,15%	0,00%	3,85%	0,00%	0,00%	0,00%	0,00%	0,00%
[25.0 - 26.0]	0,00%	95,92%	4,08%	0,00%	0,00%	0,00%	0,00%	0,00%
[26.0 - 27.0]	0,00%	0,00%	97,77%	0,56%	0,00%	1,68%	0,00%	0,00%
[27.0 - 28.0]	0,00%	0,97%	0,00%	97,09%	1,94%	0,00%	0,00%	0,00%
[28.0 - 29.0]	0,99%	0,00%	0,00%	1,98%	96,04%	0,99%	0,00%	0,00%
[29.0 - 30.0]	0,00%	0,00%	1,04%	0,00%	2,08%	95,83%	0,00%	1,04%
[30.0 - 31.0]	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
[31.0 - 100.0]	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	100,00%

Fonte: Autoral (2023)

Umidade

Uma observação das mudanças de estado referente a umidade, criados 9 diferentes estados de transição, sendo que a umidade mais baixa registrada foi de 57%, e mais alta 81% aproximadamente. Neste sentido, foi criado as faixas e sua matriz de transição conforme:

Tabela 3. Contagem de Transições para Calcular as Probabilidades da Umidade

	[0 - 62.5]	[62.5 - 65.0]	[65.0 - 67.5]	[67.5 - 70.0]	[70.0 - 72.5]	[72.5 - 75.0]	[75.0 - 77.5]	[77.5 - 80.0]	[80.0 - 100]
[0 - 62.5]	58	1	0	0	0	0	0	0	0
[62.5 - 65.0]	1	35	1	1	0	0	0	0	0
[65.0 - 67.5]	0	1	115	2	0	0	0	2	0
[67.5 - 70.0]	1	0	3	103	1	0	0	0	0
[70.0 - 72.5]	0	0	0	0	50	2	0	1	0
[72.5 - 75.0]	0	0	1	1	2	104	4	0	0
[75.0 - 77.5]	0	0	0	0	0	4	10	0	0
[77.5 - 80.0]	0	1	0	1	0	1	0	75	0
[80.0 - 100]	0	0	0	0	0	1	0	0	22

Fonte: Autoral (2023)

Tabela 4. Matriz de Transição da Umidade

	[0 - 62.5]	[62.5 - 65.0]	[65.0 - 67.5]	[67.5 - 70.0]	[70.0 - 72.5]	[72.5 - 75.0]	[75.0 - 77.5]	[77.5 - 80.0]	[80.0 - 100]
[0 - 62.5]	98,31%	1,69%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
[62.5 - 65.0]	2,63%	92,11%	2,63%	2,63%	0,00%	0,00%	0,00%	0,00%	0,00%
[65.0 - 67.5]	0,00%	0,83%	95,83%	1,67%	0,00%	0,00%	0,00%	1,67%	0,00%
[67.5 - 70.0]	0,93%	0,00%	2,78%	95,37%	0,93%	0,00%	0,00%	0,00%	0,00%
[70.0 - 72.5]	0,00%	0,00%	0,00%	0,00%	94,34%	3,77%	0,00%	1,89%	0,00%
[72.5 - 75.0]	0,00%	0,00%	0,89%	0,89%	1,79%	92,86%	3,57%	0,00%	0,00%
[75.0 - 77.5]	0,00%	0,00%	0,00%	0,00%	0,00%	28,57%	71,43%	0,00%	0,00%
[77.5 - 80.0]	0,00%	1,28%	0,00%	1,28%	0,00%	1,28%	0,00%	96,15%	0,00%
[80.0 - 100]	0,00%	0,00%	0,00%	0,00%	0,00%	4,35%	0,00%	0,00%	95,65%

Fonte: Autoral (2023)

Determinando o vetor de estado inicial da temperatura

Durante o estudo, o período mostra 8 faixas. A probabilidade de ocorrência dessas faixas pode ser obtida pela contagem dos 606 dados de temperatura. O vetor inicial é indicado por $\pi(0)$ e dado por $\pi(0) = (\pi(1), \pi(2), \pi(3), \dots, \pi(8))$. Então,

$$\begin{aligned} \pi (1) &= 26/606 = 4,29\% \\ \pi (2) &= 49/606 = 8,09\% \\ \pi (3) &= 179/606 = 29,54\% \\ \pi (4) &= 103/606 = 17,00\% \\ \pi (5) &= 101/606 = 16,67\% \\ \pi (6) &= 96/606 = 15,84\% \\ \pi (7) &= 0/606 = 0,00\% \\ \pi (8) &= 52/606 = 8,58\% \end{aligned} \quad (1)$$

Determinando o vetor de estado inicial da umidade

Durante o estudo, o período mostra 9 faixas. A probabilidade de ocorrência dessas 9 faixas pode ser obtida pela contagem dos 606 dados de temperatura. O vetor inicial é indicado por $\psi (0)$ e dado por $\psi (0) = (\psi (1), \psi (2), \psi (3) \dots, \psi (9))$ para umidade. Então,

$$\begin{aligned} \psi (1) &= 60/606 = 9,90\% \\ \psi (2) &= 38/606 = 6,27\% \\ \psi (3) &= 120/606 = 19,80\% \\ \psi (4) &= 108/606 = 17,82\% \\ \psi (5) &= 23/606 = 8,75\% \\ \psi (6) &= 112/606 = 18,48\% \\ \psi (7) &= 14/606 = 2,31\% \\ \psi (8) &= 78/606 = 12,87\% \\ \psi (9) &= 23/606 = 3,80\% \end{aligned} \quad (2)$$

Cálculo das probabilidades de estado da Temperatura e Umidade

O modelo de Cadeias de Markov sugere que, a probabilidade de estado por vários períodos pode ser obtida pela multiplicação da probabilidade da matriz de transição e o vetor de estado inicial $\psi (i + 1) = \psi (i) \cdot P$. Onde, $\psi (i)$ é o vetor estado para estado i e P é a probabilidade da matriz de transição.

Neste sentido, o vetor para umidade no tempo $\psi (1) = (10,06\%, 6,27\%, 19,89\%, 17,82\%, 8,75\%, 18,48\%, 2,31\%, 12,87\%, 3,63\%)$. E o vetor para temperatura no tempo $\pi (1) = (4,29\%, 7,98\%, 29,54\%, 17,00\%, 16,67\%, 15,84\%, 0,00\%, 8,75\%)$.

Quando um processo Markoviano é capaz de ir de qualquer estado para outro, atinge assim a condição de regime estacionário e descrito como matriz ergódica. Então para atingir o estado estacionário na presente pesquisa foi multiplicado a matriz de transição em um número relativamente alto de vezes com o auxílio computacional e a linguagem de programação em Python e a única matriz que houve estado estacionário foi a matriz de umidade com o vetor $\psi = (23,62\%, 9,04\%, 19,72\%, 17,54\%, 6,28\%, 10,81\%, 1,35\%, 11,63\%, 0,00\%)$.

Nota-se que como não foram encontrados nenhuma informação de temperatura do estado (30.0 – 31.0) e assim a temperatura não encontrou estado estacionário, tendo em vista que não foi capaz de realizar uma transição de estado para o outro.

Discussão

Partindo do ponto do estado estacionário da matriz de umidade, dentro dessas condições se pode afirmar que a umidade de faixa (0 – 62.5) é que possui maior probabilidade de 23,62% de permanecer nessa faixa ao longo desses períodos e de acordo com o estado inicial houve um aumento já que na faixa inicial eram 9,90%. Nesta perspectiva, ao verificar os estados iniciais com o resultado estacionário se pode notar que as faixas com menores índices são as que aumentaram, ou seja, a umidade terá uma maior probabilidade de estar abaixo de

70% de umidade.

Apesar dos índices de temperatura não entrarem em estado estacionário, e utilizando a mesma quantidade computacional para estado de ergodicidade da umidade, as faixas que tendem aumentar as probabilidades de ocorrerem ficam entre (28 – 31+) e que são as últimas faixas. Quanto maior o número de iterações maiores fica as faixas de temperatura.

Conclusões

O modelo de Cadeias de Markov para analisar comportamento da temperatura e umidade mostra que é completamente afetado por fatores estocásticos. Neste sentido, a oscilação tanto da temperatura e umidade ocorrem de forma gradativamente lenta. A predição do comportamento da temperatura e umidade é muito complicado por causa de inúmeros fatores: como a localidade; se ambiente que está sendo analisado ocorre circulação natural de ar. Tais fatores que podem trazer informações que não são fidedignas. Dada tal complexidade as tomadas de decisão são muito mais assertivas para coletas de campo em suas respectivas pesquisas com as probabilidades calculadas por Cadeias de Markov.

Este estudo de Cadeias de Markov é aplicado para predizer o comportamento da temperatura e umidade. Os resultados são expressos em termos de probabilidade de um certo estado de temperatura e umidade no futuro. O modelo não fornece os resultados de estado absoluto. O vetor de estado inicial e as matrizes de transição são usados para estimar os próximos passos em diferentes estados.

A pesquisa evidenciou que a matriz de transição da Temperatura tende a aumentar as probabilidades para que ocorram entre (28 a 30+) e que na umidade terá uma maior probabilidade de estar abaixo de 70% de umidade.

Referências

ABDUL-NIBY, M.; FARHAT, M.; ABDULLAH, M.; NAZZAL, A. A low-cost automated weather station for real time local measurements. *Engineering, Technology & Applied Science Research*, 7 (3), 1615–1618, 2017.

AZEVEDO, P. D.; LEITÃO, M. M. V. B. R. Aplicação de processos em cadeia de Markov às precipitações diárias no Estado da Paraíba. *Revista Brasileira de Meteorologia*, 5 (1), p. 389-402, 1990.

BOLSON, M.; BORELLA, L.; TOMÉ, F.; ORLANDIN, B.; CORSO, L. Aplicação de cadeias de markov para análise de variação do dólar americano, 2019.

BREINL, K.; TURKINGTON, T.; STOWASSER, M. Stochastic generation of multi-site daily precipitation for applications in risk management. *Journal of Hydrology*, 498, p. 23-35, 2013.

CARVALHO, A. L. De.; SOUZA, J. L. D.; LYRA, G. B.; WANDERLEY, H. S. Aplicação da cadeia de Markov para dias secos e chuvosos. *Revista Brasileira de Meteorologia*, v. 32, p. 207-214, 2017.

DA SILVA, J. J.; JÚNIOR, S. F. A. X.; XAVIER, É. F. M.; STOŠIĆ, T.; STOŠIĆ, B.; FERREIRA, T. A. E. Application of Markov chain on daily rainfall data in Paraíba-Brazil from 1995-2015. *Acta Scientiarum. Technology*, v. 41, 2019.

DE AMORIM, J. F.; DA SILVA, A. S. A.; XIMENES, P. D. S. M. P.; MENEZES, R. S. C. Avaliação do inverse distance weighting para estimar a precipitação na Mesorregião Agreste do Estado de Pernambuco, Brasil. *Sigmae*, 8(2), p. 340-347, 2019.

DE MATOS, B. G.; BORELLA, L. de C.; ORLANDIN, B. C.; MORAES, N. T.; CORSO, L. L. Aplicação de Cadeias de Markov na Avaliação da Transição do Clima na Cidade de São Paulo Application of Markov Chains in the Assessment of Climate Transition in Sao Paulo City. Disponível em: <http://aprepro.org.br/combrep/2019/anais/arquivos/02292020_160211_5e5ac2537edd4.pdf>.

DOS SANTOS, A. M.; DE ARAÚJO, L. E.; ANDRADE, E. C. D. A.; ALVES, A. S. Avaliação Temporal da Climatologia do Litoral Norte da Paraíba (Temporal Evaluation of Climatology Northern Coast of Paraíba). *Revista Brasileira de Geografia Física*, 5 (3), p.467-472, 2012.

DOS SANTOS, F. S.; DO NASCIMENTO, K. K. F.; DA SILVA, J. J.; FERREIRA, T. A. E. Análise de Velocidade do Vento em Petrolina-PE Usando Cadeias de Markov de Ordem Superior. *Sigmae*, 8(2), p. 385-392, 2019.

FERREIRA, C. D. C. M. ESTUDO DO COMPORTAMENTO DO PERÍODO CHUVOSO EM JUIZ DE FORAMG. *Revista Geonorte*, 3(8), p. 953-963, 2012.

GROSSI, R. M. Cadeias de Markov aplicadas à definição de camadas litológicas para modelos numéricos de fluxo de águas subterrâneas. 2020. Tese de Doutorado. Universidade de São Paulo.

HUSSEIN, Z. K.; HADI, H. J.; ABDUL-MUTALEB, M. R.; MEZAAL, Y. S. Low cost smart weather station using Arduino and ZigBee. *Telkomnika (Telecommunication Computing Electronics and Control)*, 18 (1), p. 282-288, 2020.

KELLER FILHO, T., Zullo Junior, J., & Lima, P. R. S. D. R. (2006). Análise da transição entre dias secos e chuvosos por meio da cadeia de Markov de terceira ordem. *Pesquisa Agropecuária Brasileira*, 41, p. 1341-1349.

KODALI, R. K.; MANDAL, S. IoT based weather station. In *2016 international conference on control, instrumentation, communication and computational technologies (ICCICCT)*, p. 680-683, 2016.

LENNARTSSON, J.; BAXEVANI, A.; CHEN, D. Modelling precipitation in Sweden using multiple step Markov chains and a composite model. *Journal of hydrology*, 363(1-4), p. 42-59, 2008.

MINUZZI, R. B. Aplicação da Cadeia de Markov para previsão mensal de chuva em Santa Catarina durante o El Niño Oscilação Sul. *Geosul*, v. 32, n. 64, p. 126-136, 2017.

MOUSINHO, F. E. P., DE ANDRADE, A. S. J.; GONÇALVES, A. C. A.; FRIZZONE, J. A. Variabilidade espacial dos percentis 75 da precipitação pluvial anual para o Estado do Piauí. *Irriga*, 11(2), p. 178-187, 2006.

PASQUAL, A. L. K.; LIPOSKI, J.; CORSO, L. L. Aplicação de Cadeias de Markov para Determinação de Probabilidades de Estados Climáticos na Cidade de Caxias do Sul. *Caxias do Sul: XXXVI ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO*, 2016.

PIÑERES-ESPITIA, G.; CAMA-PINTO, A.; DE LA ROSA, D.; ESTEVEZ, F.; CAMA-PINTO, D. Design of a low-cost weather station for detecting environmental changes, 2017.

SOUSA, R. R.; ANTUNES, J. P.; CABRAL, I. Estação meteorológica experimental de baixo custo. *Geo UERJ*, (27), p. 80-97, 2015.

STERN, R. D.; DENNETT, M. D.; DALE, I. C. Analyzing daily rainfall measurements to give agronomically useful results. I. Direct methods. *Experimental Agriculture*, 18(3), p. 223-236, 1982.

Recebido em 3 dezembro de 2023.
Aceito em 11 de outubro de 2023.