



UNIVERSIDADE ESTADUAL DA PARAÍBA  
CENTRO DE CIÊNCIAS E TECNOLOGIA  
DEPARTAMENTO DE ESTATÍSTICA

Leandro Valter Gomes

**MODELOS LINEARES DINÂMICOS  
GENERALIZADOS EM CASOS  
NOTIFICADOS DE DENGUE NA CIDADE DE  
CAMPINA GRANDE-PB**

Campina Grande - PB

12 de dezembro de 2018

Leandro Valter Gomes

**MODELOS LINEARES DINÂMICOS GENERALIZADOS  
EM CASOS NOTIFICADOS DE DENGUE NA CIDADE  
DE CAMPINA GRANDE-PB**

Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Estatística do Departamento de Estatística do Centro de Ciências e Tecnologia da Universidade Estadual da Paraíba em cumprimento às exigências legais para obtenção do título de bacharel em Estatística.

Orientador: Prof. Dr. Kleber Napoleão Nunes de Oliveira Barros

Campina Grande - PB  
12 de dezembro de 2018

É expressamente proibido a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano do trabalho.

G633m Gomes, Leandro Valter.

Modelos lineares dinâmicos generalizados em casos notificados de dengue na cidade de Campina Grande-PB [manuscrito] / Leandro Valter Gomes. - 2018.

32 p. : il. colorido.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Estatística) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2018.

"Orientação : Prof. Dr. Kleber Napoleão Nunes de Oliveira Barros, Coordenação do Curso de Estatística - CCT."

1. Modelo de Poisson Dinâmico . 2. Inferência Bayesiana.  
3. Séries Temporais. I. Título

21. ed. CDD 519.5

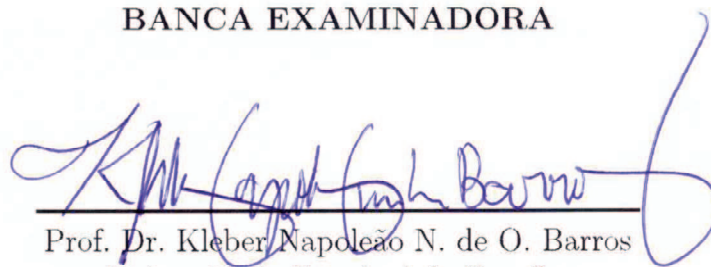
Leandro Valter Gomes

# MODELOS LINEARES DINÂMICOS GENERALIZADOS EM CASOS NOTIFICADOS DE DENGUE NA CIDADE DE CAMPINA GRANDE-PB

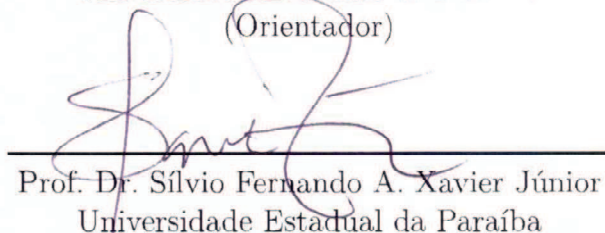
Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Estatística do Departamento de Estatística do Centro de Ciências e Tecnologia da Universidade Estadual da Paraíba em cumprimento às exigências legais para obtenção do título de bacharel em Estatística.

Trabalho aprovado em 12 de dezembro de 2018.

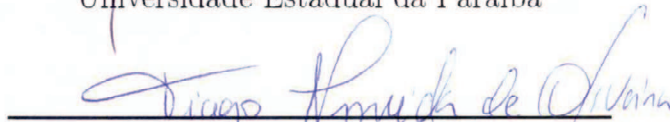
## BANCA EXAMINADORA



Prof. Dr. Kleber Napoleão N. de O. Barros  
Universidade Estadual da Paraíba  
(Orientador)



Prof. Dr. Sílvio Fernando A. Xavier Júnior  
Universidade Estadual da Paraíba



Prof. Dr. Tiago Almeida de Oliveira  
Universidade Estadual da Paraíba

# Agradecimentos

A Deus por ter me dado saúde, coragem e força para superar as dificuldades ao longo do curso. A minha mãe, Cláudia, anjo que me deu todo amor nas horas difíceis, de tristeza e cansaço. Ao meu pai, Evandro (*in memoriam*), que deixou-me uma imensa saudade mas sempre viverá em mim e em meu irmão. Ao meu irmão, Lucas, pelo seu carinho e exemplo de força. A toda minha família, em especial a meus avós, Nina, Lúcia e Claudenor, e aos meus tios, Ricardo, Vâninha, Roberto, Fernanda, Clésia, Alberto, Cláudio, Murillo e Mirele, que nos momentos chorosos de despedida e nos momentos alegres da chegada me acomodavam em calorosos abraços e beijos.

Ao meu orientador Kleber, pela paciência e confiança. Aos professores, Gustavo, Diana, Ana Patrícia, Ednário, Pollyanna, Érika, Vitória, Giselly, Juarez, Joseane, Charles, Onildo e Gustavo, pela dedicação no ensino. Em especial, aos professores, Ricardo, Tiago e Sílvio, pela amizade criada ao longo do curso. Muito obrigado por acreditarem no meu potencial e pelos conselhos que me ajudaram a escolher meu caminho.

Aos amigos e colegas de curso, Cleanderson, Kildery, Natacha, Arthur, Elvys, Sandro, Daniel, Alexandrino, Raquel, Josefa, Elizandra, Mateus, Rafaela, Ívson, Gustavo, Janaína, Fábio, Pedro, Débora, Lucas, Hiago, Tiago, Ricardo, Pâmella pelo convívio no curso. Em especial a Alisson e Rodolfo, irmãos que sempre estiveram por perto em momentos de alegria e de tristeza, convivendo dia após dia, compartilhando dos meus sonhos para o futuro.

Ao Departamento de Estatística, que consegue tirar leite de pedra, sempre tentando melhorar. Aos secretários da coordenação, Wilson, Paulo e Josemberg, pelo profissionalismo e tato para lidar com os estudantes e professores.

A todos que acreditaram em mim e fizeram/fazem parte da minha vida, obrigado a todos.

*“Olhe para um dia em que você está extremamente satisfeito no final. Não é um dia em que você fica sem fazer nada; é um dia que você teve tudo para fazer e você fez.”*  
*(Margaret Thatcher)*

*“Saber não é suficiente, devemos aplicar o conhecimento. Estar disposto não é suficiente, é preciso mover-se.”*  
*(Bruce Lee)*

*“A melhor coisa sobre ser um estatístico é que você começa a brincar no quintal de todos.”*  
*(John Tukey)*

# Resumo

É abordado neste trabalho a modelagem de séries temporais mensais dos casos notificados de dengue e variáveis meteorológicas, na cidade de Campina Grande-PB, aplicando os modelos lineares dinâmicos generalizados bayesiano no período de janeiro de 2007 a dezembro de 2017. A metodologia utilizada foi a aplicação do modelo dinâmico com distribuição Poisson juntamente com as variáveis meteorológicas. Foram aplicadas simulações de Monte Carlo via Cadeias de Markov (MCMC) para estimação de parâmetros, e a estatística de *Deviance Information Criterion* (DIC) para seleção de modelos. O modelo que apresentou o melhor ajuste, com o menor valor de DIC, foi o modelo com as variáveis meteorológicas precipitação, temperatura e umidade, com este modelo foi realizada a previsão. O modelo dinâmico de Poisson via inferência Bayesiana obteve um bom ajuste aos dados notificados, produzindo uma modelagem útil para tomada de decisões na saúde pública, ajudando nas campanhas de prevenção, possibilitando um direcionamento mais eficiente de verbas no combate a dengue.

**Palavras-chaves:** Modelo de Poisson Dinâmico, Inferência Bayesiana, Séries Temporais.

# Abstract

The present study deals with the modeling of monthly time series of reported cases of dengue and meteorological variables in the city of Campina Grande, Brazil, applying Bayesian generalized dynamic linear models from January 2007 to December 2017. The methodology used was the application of the dynamic model with Poisson distribution together with the meteorological variables. Markov Chain Monte Carlo (MCMC) simulations were applied for parameter estimation, and the Deviance Information Criterion (DIC) statistic for model selection. The model that presented the best adjustment, with the lowest DIC value, was the model with the meteorological variables precipitation, temperature and humidity, with this model the forecast was made. The dynamic model of Poisson via Bayesian inference obtained a good adjustment to the data reported, producing a useful model for public health decision making, helping in prevention campaigns, enabling a more efficient allocation of funds in the fight against dengue.

**Key-words:** Dynamic Poisson Model, Bayesian Inference, Time series.



# Lista de ilustrações

Figura 1 – Casos notificados de dengue na cidade de Campina Grande-PB. . . . .	21
Figura 2 – Séries temporais das variáveis meteorológicas da cidade de Campina Grande-PB. . . . .	21
Figura 3 – <i>Monthplot</i> dos casos notificados de dengue na cidade de Campina Grande-PB . . . . .	22
Figura 4 – Decomposição da série . . . . .	22
Figura 5 – Ajuste pelo modelo dinâmico de Poisson com as variáveis meteorológicas Precipitação, Temperatura e Umidade. . . . .	24
Figura 6 – Desidade e iterações para $\alpha_t$ . . . . .	31
Figura 7 – Desidade e iterações para $\eta_t$ . . . . .	31
Figura 8 – Desidade e iterações para $\beta_{1,t}$ . . . . .	32
Figura 9 – Desidade e iterações para $\beta_{2,t}$ . . . . .	32
Figura 10 – Desidade e iterações para $\beta_{3,t}$ . . . . .	32

# Lista de tabelas

Tabela 1 – Estatísticas descritivas para os casos notificados de dengue na cidade de Campina Grande-PB. . . . .	20
Tabela 2 – Teste de Estacionaridade Phillips-Perron . . . . .	23
Tabela 3 – Comparação dos modelos pelo DIC e RMSE . . . . .	23
Tabela 4 – Estimativas dos parâmetros do modelo dinâmico de Poisson. . . . .	24
Tabela 5 – Previsão mensal da incidência com os respectivos intervalos de credibilidade à 95%. . . . .	25

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>10</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>12</b>
<b>2.1</b>	<b>Séries Temporais</b>	<b>12</b>
2.1.1	Teste de Estacionaridade: Phillips-Perron	12
<b>2.2</b>	<b>Inferência Bayesiana</b>	<b>13</b>
2.2.1	Teorema de Bayes	13
2.2.2	Abordagem Bayesiana para Previsão	14
2.2.3	Monte Carlo via Cadeias de Markov (MCMC)	14
2.2.3.1	Cadeias de Markov	14
2.2.3.2	Algoritmo de Metropolis-Hastings	15
<b>2.3</b>	<b>Comparação de Modelos</b>	<b>15</b>
2.3.1	Deviance Information Criterion (DIC)	15
2.3.2	Raiz do Erro Quadrático Médio (RMSE)	16
<b>2.4</b>	<b>Modelos Lineares Dinâmicos (MLD)</b>	<b>16</b>
<b>2.5</b>	<b>Modelos Lineares Dinâmicos Generalizados (MLDG)</b>	<b>17</b>
2.5.1	Modelo de Poisson Dinâmico	18
<b>3</b>	<b>RESULTADOS</b>	<b>20</b>
<b>3.1</b>	<b>Análise Exploratória</b>	<b>20</b>
<b>3.2</b>	<b>Ajuste do Modelo Dinâmico de Poisson via inferência bayesiana</b>	<b>23</b>
<b>4</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>26</b>
	<b>REFERÊNCIAS</b>	<b>27</b>
	<b>APÊNDICE A – MODELO DINÂMICO DE POISSON PELO OPEN-BUGS</b>	<b>29</b>
	<b>APÊNDICE B – MODELO DINÂMICO DE POISSON PELO R</b>	<b>30</b>
	<b>APÊNDICE C – DENSIDADES E INTERAÇÕES DA SIMULAÇÃO DOS PARÂMETROS DO MODELO.</b>	<b>31</b>

# 1 Introdução

A dengue é considerada, entre as arboviroses, uma das doenças mais graves do mundo e apresenta uma grande incidência em países tropicais, estando profundamente relacionada tanto a condições climáticas quanto a fatores políticos, econômicos e sócio-ambientais. Essas condições favorecem a proliferação do mosquito transmissor, o *Aedes aegypti*. Segundo Ferreira, Chiaravalloti e Mondini (2018), a dengue é uma doença viral que se caracteriza como um grave transtorno de saúde pública. Causada pela infecção por um dos quatro sorotipos do vírus da dengue (DENV 1-4), transmitidos por mosquitos do gênero *Aedes*, onde a infecção é muitas vezes não evidente e em muitos casos é assintomática.

Segundo Tauil (2002), a dengue tem destaque entre as arboviroses como a doença reemergente mais grave no mundo, cerca de 2,5 bilhões de pessoas encontram-se sob risco de infecção, principalmente em países tropicais onde a precipitação, temperatura e umidade favorecem a difusão do mosquito transmissor.

Segundo Saúde (2016), o ciclo de transmissão da doença desencadeia quando a fêmea do mosquito *Aedes aegypti* pica uma pessoa com dengue. Então de 8 a 12 dias o vírus começa a se reproduzir no organismo, após esse tempo, o mosquito começa a infectar outras pessoas, picando um ser humano sadio, transmitindo o vírus para o sangue dessa pessoa. Depois do vírus no organismo, a doença começa a se manifestar.

No Brasil, a dengue é uma doença endêmica, ou seja, ocorre habitualmente e com uma incidência significativa na população. O crescimento desordenado das cidades pode facilitar o criadouro dos mosquitos, dado que gera deficiências no abastecimento regular de água e na coleta e no destino adequado do lixo.

A cidade de Campina Grande-PB anualmente vem sofrendo casos de surtos de dengue, seja por falta de consciência da população ou desleixo das instituições responsáveis, proporcionando um descontrole do vetor transmissor.

A contagem de casos notificados de dengue pode ser modelada através do uso de análise de séries temporais, contemplando diversas metodologias para análise, como Modelo Autorregressivo Integrado de Médias Móveis (ARIMA) (MARTINEZ; SILVA, 2011), o Modelo Generalizado Autorregressivo de Médias Móveis (GARMA) (ANDRADE; ANDRADE; EHLERS, 2015) e o Modelo Linear Dinâmico Generalizado (MLDG) (MARTÍNEZ-BELLO; LÓPEZ-QUÍLEZ; TORRES-PRIETO, 2017).

Os Modelos Lineares Dinâmicos (MLD) discutidos por West e Harrison (1997), são divididos com base em duas equações. A primeira, denominada equação de observação, que descreve o caráter estocástico da variável resposta em relação a outras variáveis

explicativas e a segunda, chamada de equação de evolução, descreve a variação estocástica dos coeficientes de regressão.

Os Modelos Lineares Dinâmicos Generalizados (MLDG)(WEST; HARRISON; MIGON, 1985) são extensões dos Modelos Lineares Dinâmicos (MLD), baseando-se em duas equações, uma equações contemplando as observações e a equação de transição de estado. A equação de observação estabelece uma ligação entre observações e variáveis não observadas, e as equações de transição descrevem a evolução das variáveis de estado. A vantagem do MLDG é a possibilidade de incluir componentes de tendência, sazonalidade e covariáveis.

A característica principal destes modelos consiste nos parâmetros do modelo estarem sujeitos a variações ao longo do tempo. Os parâmetros possuem uma distribuição e que esta pode ser obtida a partir da inferência Bayesiana por meio da preditiva.

Nesse estudo foi realizada a modelagem via inferência bayesiana dos casos de dengue no município de Campina Grande-PB, ajustando-se um modelo linear dinâmico generalizado com o objetivo de entender o comportamento dos casos notificados em relação a variáveis meteorológicas e fazer previsões para auxiliar em medidas de prevenção da doença na cidade.

## 2 Fundamentação Teórica

### 2.1 Séries Temporais

Uma série temporal pode ser definida como uma sequência de observações realizadas sequencialmente ao longo do tempo. Exemplos de séries temporais podem ser vistos nas mais diversas áreas seja na economia, epidemiologia, engenharias, ciências naturais (principalmente na meteorologia) e ciências sociais. As observações vizinhas são estocasticamente dependentes. A análise de séries temporais tem por finalidade compreender e descrever o comportamento da série e a previsão de valores futuros a partir dos valores presentes e passados (BOX; JENKINS; REINSEL, 2008).

As séries temporais são formadas pelo conjunto de observações  $\{Y_t, t \in T\}$ , onde  $Y_t$  é variável de interesse observada no tempo  $t$  e  $T$  é o conjunto de tempos, podendo ser classificado como discreto ou contínuo. Caso se trate de uma série temporal multivariada as observações são definidas como  $\{\mathbf{Y}_t, t \in T\}$ , onde os  $\mathbf{Y}'_t$ s são vetores de variáveis aleatórias.

Existem diversos modelos utilizados para a previsão de séries temporais, onde se destaca a modelagem Box–Jenkins, essa metodologia que envolve o modelo Autorregressivo Integrado de Médias Móveis (ARIMA). Os modelos da classe ARIMA são famosos por serem flexíveis, pois permitem ajustes e adaptações nos seus parâmetros, podendo se adequar a diversos tipos de séries temporais conseguindo uma estrutura de correlação linear entre os valores vizinhos das séries temporais.

Segundo Morettin e Tolo (2006), para compreender o comportamento de uma série temporal é preciso conhecer seus componentes característicos: estacionaridade, tendência, sazonalidade, ciclo e erro aleatório.

Mais detalhes em (BOX; JENKINS; REINSEL, 2008; MORETTIN; TOLOI, 2006).

#### 2.1.1 Teste de Estacionaridade: Phillips-Perron

A estacionaridade é uma importante característica que se deve identificar para entender o comportamento de uma série temporal. O teste de Phillips-Perron (PHILLIPS; PERRON, 1988) conhecido na literatura como teste PP que é uma generalização do teste de raiz unitária de Dickey-Fuller (DICKEY; FULLER, 1979) para dados onde os erros são correlacionados. As hipóteses do teste PP são

$$\begin{cases} H_0: \text{A série possui raiz unitária} \\ H_1: \text{A não possui raiz unitária} \end{cases}$$

Caso o p-valor do teste seja  $< 0,05$  rejeitamos  $H_0$  com 5% de significância, ou seja, A série não possui raiz unitária, portanto a série é estacionária.

## 2.2 Inferência Bayesiana

A inferência Bayesiana é uma área da estatística na qual a estimação dos parâmetros do modelo pode ser quantificada através de uma distribuição de probabilidade. A distribuição à priori quantifica a informação que o pesquisador tem sobre os parâmetros e as inferências desses parâmetros provêm da distribuição à posteriori, sendo esta, uma ponderação entre a informação do pesquisador e a função de verossimilhança.

### 2.2.1 Teorema de Bayes

Segundo Ntzoufras (2009),  $\theta$  é um vetor de parâmetros a ser estimado, com espaço paramétrico  $\Theta$  e  $Y$  uma variável aleatória. Pelo Teorema de Bayes, a distribuição a posteriori para  $\theta$ , é dada por

$$p(\theta|y) = \frac{p(\theta)p(y|\theta)}{\int_{\Theta} p(\theta)p(y|\theta)}, \quad (2.1)$$

sendo  $\theta$  contínuo,  $p(\theta)$  a distribuição a priori e  $p(y|\theta) = \prod_{i=1}^n p(y_i|\theta)$  é função de verossimilhança de  $\theta$ , onde é permitido estimar o valor dos parâmetros a partir de um conjunto de dados. A equação (2.1) pode ser reescrita na seguinte forma

$$p(\theta|y) \propto p(\theta)p(y|\theta). \quad (2.2)$$

Isto é, omitindo-se  $p(y)$  no denominador, a igualdade é substituída pela proporcionalidade, simplificando o teorema de Bayes.

A partir da equação (2.2) a constante normalizadora ( $p(y)$ ) da posteriori em (2.1) é alcançada com

$$p(y) = \int p(y, \theta)d\theta = \int p(y|\theta)p(\theta)d\theta = E_{\theta}[p(Y|\theta)] \quad (2.3)$$

que é chamada de distribuição *preditiva* a priori. Essa é a distribuição esperada para  $y$  dado  $\theta$ , antes da realização do experimento ou observação dos dados. A distribuição preditiva  $\tilde{Y}$  dado  $y$  é alcançada pela integração

$$p(\tilde{y}|y) = \int p(\tilde{y}|\theta, y)d\theta = \int p(\tilde{y}|\theta, y)p(\theta, y)d\theta = E_{\theta|y}[p(\tilde{Y}|\theta)]. \quad (2.4)$$

## 2.2.2 Abordagem Bayesiana para Previsão

Segundo Pole, West e Harrison (1994), uma previsão é uma declaração de probabilidade ou, mais geralmente, declara-se uma distribuição de probabilidade que quantifica a natureza da incerteza. Toda previsão é baseada em uma fonte de conhecimento, as previsões são, portanto, declarações de probabilidade condicional, sendo o condicionamento o estado de conhecimento existente. O modelo bayesiano fornece uma estrutura coerente e formal para combinar informações. Todas as previsões bayesianas são probabilísticas e são dadas através da eq. (2.4).

Em suma, a abordagem Bayesiana permite que informações não contidas nos dados sejam incorporadas ao modelo. A possibilidade de se obter informações externas será sempre um ponto positivo a favor da inferência Bayesiana.

## 2.2.3 Monte Carlo via Cadeias de Markov (MCMC)

Os métodos Bayesianos podem ser bastantes complexos, dependendo do caso, encontrar a distribuição a posteriori pode ser impraticável. Através dos métodos de simulação de Monte Carlo via Cadeias de Markov (MCMC), pode-se obter uma amostra da distribuição a posteriori e o cálculo das estimativas amostrais dessa distribuição, utilizando técnicas iterativas baseadas nas cadeias de Markov. De acordo com Ntzoufras (2009), os métodos MCMC simulam um passeio aleatório no espaço  $\theta$ , tendendo para uma distribuição estacionária, que é a distribuição de interesse do problema.

### 2.2.3.1 Cadeias de Markov

Uma cadeia de Markov é um processo estocástico  $X_0, X_1, \dots$ , onde  $X_i, i = 1, \dots, t$  representa uma variável aleatória, com possíveis valores de probabilidade em um conjunto  $T$ .  $X_t$  é uma cadeia de Markov se

$$P(X_t \in T | X_0, \dots, X_{t-1}) = P(X_t \in T | X_{t-1}),$$

ou seja, a distribuição  $X_t$  depende exclusivamente de  $X_{t-1}$ .

Segundo Ntzoufras (2009), o método MCMC requer que a cadeia de Markov seja homogênea (as probabilidades na transição de um estado para o outro são invariáveis), irreduzível (a transição entre estados é atingida por um número finito de iterações) e aperiódica (onde não existam estados absorventes).

Supondo uma distribuição  $\pi(x), x \in \mathbb{R}^d$ , com pelo menos uma constante multiplicativa conhecida, complexa o bastante para não possível obter uma amostra de forma direta. Dadas as realizações  $X^{(t)}, t = 0, 1, \dots$  de uma cadeia de Markov onde  $\pi$  é a distribuição de equilíbrio, então,



$$X^{(t)} \xrightarrow{t \rightarrow \infty} \pi(x) \quad e \quad \frac{1}{n} \sum_{t=1}^n g(X_i^{(t)}) \xrightarrow{n \rightarrow \infty} E_x[g(X_i)].$$

A média teórica é estimada pela média dos valores da cadeia. Com o aumento de número de iterações, a cadeia passa a ter menos influência dos valores iniciais, converge para uma distribuição de equilíbrio, fazendo que, em aplicações, as iterações iniciais podem ser descartadas.

### 2.2.3.2 Algoritmo de Metropolis-Hastings

O algoritmo de Metropolis-Hastings é um tipo de cadeia de Markov que consiste em gerar valores de uma distribuição auxiliar, se caracterizando como um processo de reamostragem que garante a convergência da cadeia para distribuição a posteriori. Mais detalhes em Hoff (2009).

## 2.3 Comparação de Modelos

Quando existem diversos modelos que se ajustam aos dados e respondem as perguntas de interesse temos que fazer a escolha do melhor modelo. Há diversas técnicas para identificar o modelo mais adequado.

### 2.3.1 Deviance Information Criterion (DIC)

O método mais utilizado na inferência bayesiana para a escolha de modelos é o critério *Deviance Information Criterion* (DIC), sendo este, uma generalização dos critérios *Akaike Information Criterion* (AIC) e *Bayesian Information Criterion* (BIC). Segundo Moulder e Algina (2002), para um conjunto de dados  $y$  e o parâmetro do modelo  $\theta$  a estatística Deviance é definida como

$$D(y, \theta) = -2 \ln(p(y|\theta)) \quad (2.5)$$

sendo também,

$$\begin{aligned} D_{\bar{\theta}}(y) &= D(y, \bar{\theta}) \\ \bar{D}(y, \theta) &= E(D(y, \theta)|y) \\ pD &= \bar{D}(y, \theta) - D_{\bar{\theta}}(y) \end{aligned}$$

Onde  $D_{\bar{\theta}}(y)$  é a deviance calculada na média a posteriori ( $\bar{\theta}$ ),  $\bar{D}(y, \theta)$  é a deviance média a posteriori e  $pD$  o número efetivo de parâmetros. Calculamos o DIC como

$$DIC = 2\bar{D}(y, \theta) - D_{\bar{\theta}}(y). \quad (2.6)$$

Assim como outros critérios, o melhor modelo, entre os modelos em estudo, é aquele que possuir menor valor de DIC.

### 2.3.2 Raiz do Erro Quadrático Médio (RMSE)

A raiz do erro quadrático médio (RMSE) é uma medida frequentemente usada das diferenças entre os valores preditos por um modelo e os valores observados. A raiz quadrada do erro quadrático médio RMSE é calculado pela expressão

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\tilde{y}_i - y_i)^2}{n}},$$

sendo  $\tilde{y}_i$  o valor estimado e  $y_i$  o valor observado.

O RMSE é a raiz quadrada da média dos erros quadrados, sendo sensível a *outliers*, já que cada erro é proporcional ao erro quadrático médio, assim erros maiores têm um efeito desproporcionalmente grande (HYNDMAN; KOEHLER, 2006).

## 2.4 Modelos Lineares Dinâmicos (MLD)

Segundo West e Harrison (1997), o modelo linear dinâmico normal pode ser escrito de forma geral por um conjunto de quádruplos

$$\{\mathbf{F}, \mathbf{G}, \mathbf{V}, \mathbf{W}\}_t = \{\mathbf{F}_t, \mathbf{G}_t, \mathbf{V}_t, \mathbf{W}_t\} \quad (2.7)$$

para cada vez  $t$ , onde,

- $\mathbf{F}_t$  é uma matriz de constantes conhecidas ( $n \times r$ ), podendo ser um conjunto de variáveis explicativas;
- $\mathbf{G}_t$  é uma matriz conhecida ( $n \times n$ ) que descreve a evolução temporal do parâmetros de estado, conhecida como matriz de evolução;
- $\mathbf{V}_t$  é uma matriz de variação conhecida ( $r \times r$ ) associada ao erro observacional;
- $\mathbf{W}_t$  é uma matriz de variação conhecida ( $n \times n$ ) associada ao erro de evolução de estado.

Em que  $r$  é número de observações do vetor de constantes conhecidas  $\mathbf{Y}_t$  ( $r \times 1$ ) e  $n$  o número de parâmetros. Este quádruplo define o modelo que relaciona  $\mathbf{Y}_t$  ao vetor

de parâmetro  $\boldsymbol{\theta}_t(n \times 1)$  no tempo  $t$ , e a sequência  $\boldsymbol{\theta}_t$  através do tempo, através das distribuições sequencialmente especificadas

$$(\mathbf{Y}_t | \boldsymbol{\theta}_t) \sim N[\mathbf{F}'_t \boldsymbol{\theta}_t, \mathbf{V}_t], \quad (2.8)$$

e

$$(\boldsymbol{\theta}_t | \boldsymbol{\theta}_{t-1}) \sim N[\mathbf{G}_t \boldsymbol{\theta}_{t-1}, \mathbf{W}_t]. \quad (2.9)$$

As equações (2.8) e (2.9) também são implicitamente condicionais em  $D_{t-1}$ , o conjunto de informações disponível antes do tempo  $t$ . Em particular, isto inclui os valores das variâncias definidoras  $\mathbf{V}_t$  e  $\mathbf{W}_t$  e as observações passadas  $\mathbf{Y}_{t-1}, \mathbf{Y}_{t-2}, \dots$ , bem como o conjunto inicial de informações  $D_0$ . Uma representação alternativa dessas equações definidoras é

$$\mathbf{Y}_t = \mathbf{F}_t \boldsymbol{\theta}_t + \boldsymbol{\nu}_t, \boldsymbol{\nu}_t \sim N[0, \mathbf{V}_t], \quad (2.10)$$

e

$$\boldsymbol{\theta}_t = \mathbf{G}_t \boldsymbol{\theta}_{t-1} + \boldsymbol{\omega}_t, \boldsymbol{\omega}_t \sim N[0, \mathbf{W}_t]. \quad (2.11)$$

- $\mathbf{F}_t$  é a matriz de *design* de valores conhecidos de variáveis independentes;
- $\boldsymbol{\theta}_t$ , é o estado, ou sistema, vetor;
- $\boldsymbol{\mu}_t = \mathbf{F}_t \boldsymbol{\theta}_t$  é a resposta ou nível médio;
- $\boldsymbol{\nu}_t$  é o erro observacional.

As sequências de erro  $\boldsymbol{\nu}_t$  e  $\boldsymbol{\omega}_t$  são internamente e mutuamente independentes. A equação (2.10) é a equação de observação para o modelo, definindo a distribuição amostral para  $\mathbf{Y}_t$  condicional à quantidade  $\boldsymbol{\theta}_t$ . Então, dado  $\boldsymbol{\theta}_t$ ,  $\mathbf{Y}_t$  é independente de todas as outras observações e valores de parâmetros; e, em geral, dado o presente, o futuro é independente do passado. Esta equação relaciona o  $\mathbf{Y}_t$  para  $\boldsymbol{\theta}_t$  através de uma regressão linear dinâmica com uma estrutura de erro normal multivariada tendo matriz de variância observacional conhecida.

## 2.5 Modelos Lineares Dinâmicos Generalizados (MLDG)

De acordo com West, Harrison e Migon (1985), um modelo linear dinâmico generalizado pode ser definido como uma extensão dos modelos lineares dinâmicos quando a variável resposta pertence a distribuições pertencentes à família exponencial. Além disso,

o MLDG também é definido como uma extensão do Modelo Linear Generalizado (MLG), proposto por Nelder e Wedderburn (1972), quando os parâmetros dependem do tempo.

$$f(y_t|\theta_t, \phi_t) = \exp \left\{ \frac{[y_t\theta_t - b(\theta_t)]}{a(\phi_t)} + c(y_t, \phi_t) \right\} \quad (2.12)$$

Com esperança  $\mu_t = E[y_t|\theta_t, \phi_t]$ . Então, com uma função de ligação monótona e diferenciável  $g$  e um vetor preditivo  $p$ -dimensional  $\mathbf{X}_t$  incluindo um intercepto tal que

$$g(\mu_t) = \mathbf{X}_t' \boldsymbol{\beta}_t,$$

Especificando um esquema de atualização linear de primeira ordem.

$$\boldsymbol{\beta}_t = \mathbf{G}_t \boldsymbol{\beta}_{t-1} + \boldsymbol{\omega}_t, \quad t = 2, \dots, T$$

onde  $\boldsymbol{\omega}_t$  tem média 0 e matriz de covariância  $\mathbf{W}$ , com a condição inicial  $\boldsymbol{\omega}_1$ . Em séries temporais, o uso de modelos de tipo de regressão variáveis no tempo é apropriado, aplicando-se para definir o seguinte modelo linear generalizado dinâmico.

Segundo West e Harrison (1997), a abordagem bayesiana linear é um dos métodos de estimação do MLDG. É considerado como um método aproximado para estimar o primeiro e o segundo momento da distribuição a posteriori de maneira sequencial. Diversas são as aplicações com o MLDG via inferência bayesiana, ver em (TRIANTAFYLLOPOULOS, 2009; CONGDON, 2005).

### 2.5.1 Modelo de Poisson Dinâmico

O modelo dinâmico de Poisson pode ser definido como uma extensão do modelo de regressão de Poisson quando seu parâmetro é variável no tempo. Assume  $\{Y_t, t = 1, \dots, T\}$  é a série temporal para dados de contagem que seguem uma distribuição de Poisson. Então os MLDGs, com um processo de observação e um processo de transição, podem ser expressos da seguinte forma:

- Equação das observações do modelo:

$$\mathbf{y}_t | \boldsymbol{\lambda}_t \sim \text{Pois}(\boldsymbol{\lambda}_t) = \text{Pois}(\exp(\mathbf{x}_t))$$

- A função de ligação:

$$\log(\boldsymbol{\lambda}_t) = \boldsymbol{\eta}_t = g(\boldsymbol{\lambda}_t) = \mathbf{X}_t' \boldsymbol{\beta}_t$$

- Equação para mudança de estados:

$$\boldsymbol{\theta}_t = \mathbf{G}_t \boldsymbol{\theta}_{t-1} + \boldsymbol{\omega}_t, \quad \boldsymbol{\omega}_t \sim N[0, \mathbf{W}],$$

onde  $\omega_t$  é um erro de evolução que segue a distribuição Normal com média zero e variância  $\mathbf{W}$ . Existem extensões para o modelo dinâmico de Poisson que podem envolver efeitos de tendência, sazonalidade e superdispersão, como no modelo Ferreira e Gamerman (2000) para casos de meningite mensal no Rio de Janeiro.

$$\begin{aligned} \mathbf{y}_t &\sim \text{Pois}(\boldsymbol{\lambda}_t) \\ \log(\boldsymbol{\lambda}_t) &= \boldsymbol{\alpha}_t + \mathbf{s}_t + \boldsymbol{\eta}_t + \boldsymbol{\beta}_t \mathbf{X}_t \end{aligned}$$

com os efeitos mensais de tendência ( $\boldsymbol{\alpha}_t$ ) e sazonalidade ( $\mathbf{s}_t$ )

$$\begin{aligned} \boldsymbol{\alpha}_t &= \boldsymbol{\alpha}_{t-1} + \boldsymbol{\omega}_{1t} \\ \mathbf{s}_t &= -(\mathbf{s}_{t-1} + \mathbf{s}_{t-2} + \cdots + \mathbf{s}_{t-11}) + \boldsymbol{\omega}_{2t} \end{aligned}$$

onde os erros

$$\boldsymbol{\omega}_{1t} \sim N(0, \mathbf{W}_1) \quad \boldsymbol{\omega}_{2t} \sim N(0, \mathbf{W}_2)$$

com o controle do efeito de superdispersão definido como

$$\boldsymbol{\eta}_t \sim N(0, \mathbf{W}_3)$$

## 3 Resultados

Os dados referentes aos casos de dengue notificados foram cedidos pela Secretaria Estadual de Saúde da Paraíba, através do Núcleo de Transmissão de Doenças Agudas (NTDA) e as variáveis meteorológicas mensais foram obtidas pelo Instituto Nacional de Meteorologia (INMET) (INMET, 2018), no período de 1 de janeiro de 2007 à 31 de dezembro de 2017. Primeiramente foi realizada uma análise exploratória dos dados, casos notificados de dengue em conjunto com as variáveis meteorológicas que foram ajustadas no modelo posteriormente.

### 3.1 Análise Exploratória

Na Tabela 1 apresenta as estatísticas descritivas referentes aos casos notificados de dengue. Verifica-se que para todos os meses, com exceção de maio, obtiveram os valores do coeficiente de assimetria ( $C_s > 0$ ), o que indica assimetria positiva dos dados. Percebe-se que os meses, referentes ao verão, estação geralmente marcada pelas altas temperaturas e meses de chuva, nenhum caso foi notificado. O valor máximo total na série foi de 278 casos notificados em agosto. Observa-se também que existe uma alta variabilidade nos valores da série, com coeficientes de variação acima de 20% para todos os meses, sendo que o mês que apresenta uma maior variabilidade foi o mês de setembro e o mês com a menor variabilidade foi o mês de maio.

Tabela 1 – Estatísticas descritivas para os casos notificados de dengue na cidade de Campina Grande-PB.

Meses	n	Média	Mediana	Mínimo	Máximo	S	Cs	Ck	Cv%
Janeiro	11	8,09	6	0	31	9,04	1,4	0,97	111,71
Fevereiro	11	12,55	8	0	60	18,28	1,56	1,31	145,69
Março	11	22,18	15	2	74	21,57	1,22	0,34	97,25
Abril	11	36,91	20	1	114	37,73	0,68	-1,03	102,24
Maio	11	40,91	54	1	81	28,69	-0,18	-1,68	70,14
Junho	11	42,91	43	0	106	35,73	0,35	-1,34	83,27
Julho	11	47,64	26	3	208	59,18	1,73	2,01	124,24
Agosto	11	42	13	2	278	80,36	2,26	3,78	191,34
Setembro	11	30,09	7	2	236	68,58	2,43	4,4	227,91
Outubro	11	17,82	4	1	128	37,24	2,31	3,99	208,98
Novembro	11	9,91	2	0	49	16,21	1,34	0,34	163,56
Dezembro	11	6,91	2	0	43	12,44	2,16	3,48	180,02
Total	132	26,49	10	0	278	42,54	3,34	13,93	160,55

n: número de observações; S: desvio-padrão; Cv: coeficiente de variação; Cs: coeficiente de assimetria; Ck: coeficiente de curtose.

Na Figura 1 é apresentada a série temporal mensal dos casos notificados de dengue que foram registrados no período entre janeiro de 2007 até dezembro de 2017. Pode-se observar que no ano de 2013 existiu um aumento brusco em relação ao comportamento da série padrão. De acordo com a Secretaria Municipal de Saúde, em 2013 foi realizada a visita dos agentes de vigilância e foi realizado um levantamento onde viu-se que 84,3% dos focos de dengue estavam na casa dos moradores, onde foi realizado no mesmo ano um trabalho de conscientização.




Figura 1 – Casos notificados de dengue na cidade de Campina Grande-PB.

Na Figura 2 as variáveis meteorológicas Precipitação Média, Temperatura Média e Umidade Relativa Média, são apresentadas na forma de série temporal, respectivamente.

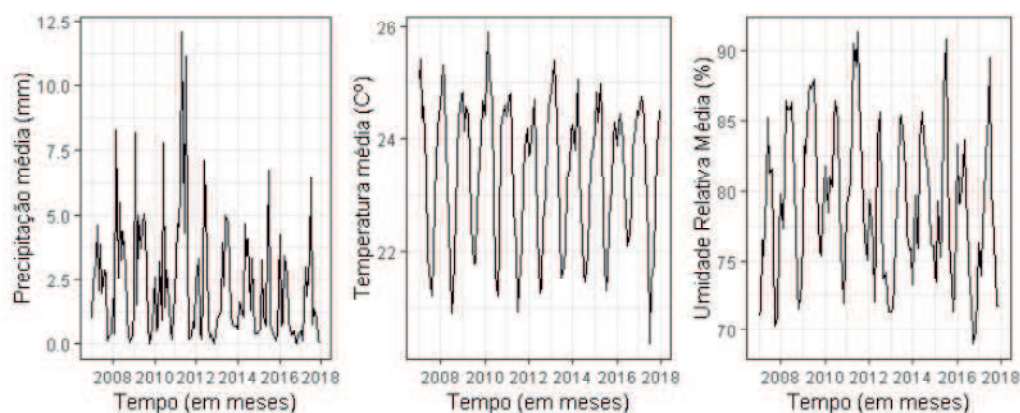


Figura 2 – Séries temporais das variáveis meteorológicas da cidade de Campina Grande-PB.

Na Figura 3 o *Monthplot* consiste em calcular as médias mensais e deixar indicado no gráfico por meio de uma reta horizontal, facilitando a visualização. A média dos casos

de dengue, em azul, indica que nos meses de janeiro, fevereiro, março, outubro, novembro e dezembro do ano há uma baixa contagem nos casos notificados.




Figura 3 – *Monthplot* dos casos notificados de dengue na cidade de Campina Grande-PB

Na Figura 4 é apresentada a decomposição da série, podendo avaliar visualmente as características da tendência, sazonalidade e aleatoriedade dos dados. observando a componente de tendência não é possível perceber um aparente crescimento ou decrescimento dos valores da série ao longo do tempo. A componente de sazonalidade é facilmente identificada através do comportamento sazonal presente nos valores observados. Na componente aleatória nota-se um comportamento ao acaso.

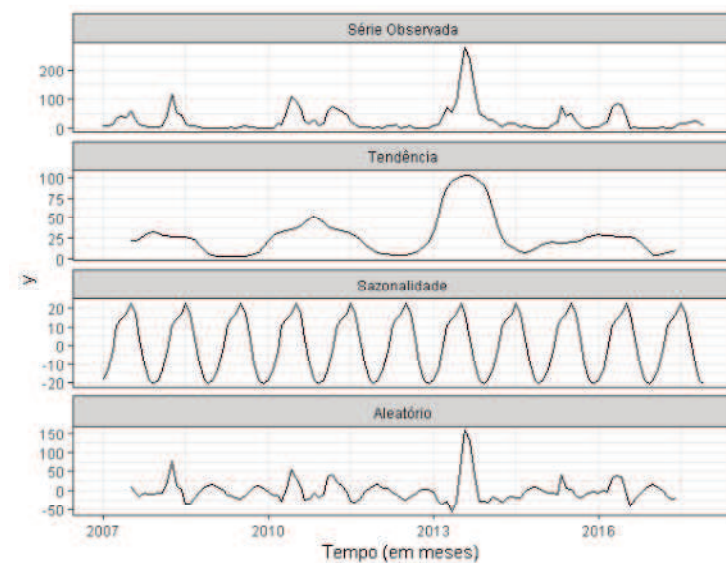


Figura 4 – Decomposição da série

Para verificação da presença de estacionariedade o teste de Philips-Perron foi realizado. Na Tabela 2 são apresentados os resultados obtidos, onde a hipótese nula, de



não-estacionaridade, foi rejeitada. Sendo assim, a série casos notificados de dengue no município de Campina Grande é estacionária, ou seja, os valores da série se concentram em torno da média com variabilidade aproximadamente constante.

Tabela 2 – Teste de Estacionaridade Phillips-Perron

Teste	Estatística	P-valor
Phillips-Perron	-29,01	<0,01

### 3.2 Ajuste do Modelo Dinâmico de Poisson via inferência bayesiana

A elaboração dos modelos foi realizada no *software* OpenBUGS (THOMAS; O'HARA, 2004) (Ver no apêndice A). Onde a execução do modelo final foi realizada pelo software R (R Core Team, 2018), através do pacote R2OpenBUGS (STURTZ; LIGGES; GELMAN, 2005) (Ver no apêndice B). As variáveis meteorológicas foram adicionadas como covariáveis no modelo dinâmico de Poisson, onde foi utilizado o algoritmo de Metropolis-Hastings para realizar as simulações pelo método de Monte Carlo via Cadeias de Markov (MCMC). Foram utilizadas 5000 iterações, com a eliminação das 500 primeiras observações, reduzindo o efeito dos valores iniciais, o que reduziu para 4500 o número de observações (ver no Apêndice C).

Na tabela 3 são apresentados os modelos de Poisson dinâmicos onde o DIC foi utilizado para escolher entre os modelos alternativos e o RMSE foi utilizado para verificar a qualidade do ajuste dos modelos.

Tabela 3 – Comparação dos modelos pelo DIC e RMSE

Modelo	$\bar{d}$	$\hat{d}$	DIC	pD	RMSE
$\alpha$	899,8	729,8	924,3	73,44	5,63
$\alpha + \eta$	707,0	548,6	790,7	95,66	1,86
$\alpha + \eta + \beta_1$	698,7	550,4	783,9	114,0	1,20
$\alpha + \eta + \beta_1 + \beta_2$	694,5	547,1	779,6	115,7	1,07
$\alpha + \eta + \beta_1 + \beta_2 + \beta_3$	695,3	540,3	777,0	118,0	0,43

Onde  $\bar{D}$  é a deviance calculada na média a posteriori,  $\hat{D}$  é a deviance média a posteriori e  $pD$  é o número efetivo de parâmetros.

O melhor ajuste, escolhido pelo menor DIC e RMSE, foi o modelo com todas as variáveis meteorológicas. Na Tabela 4, estão descritas as estimativas para os parâmetros de interesse, com as médias, os desvios e os intervalos à 95% de credibilidade. A partir dos coeficientes das variáveis meteorológicas, pode-se verificar um efeito positivo sobre os casos de dengue com o aumento do valor das covariáveis.

onde  $\beta_1$  é o coeficiente da Precipitação Média (PM),  $\beta_2$  da Temperatura Média (TM) e  $\beta_3$  da Umidade Relativa Média (URM).

Tabela 4 – Estimativas dos parâmetros do modelo dinâmico de Poisson.

Parâmetros	Médias	Desvios	2,5%	97,5%
$\alpha$	26,4518	42,9232	0,0000	139,0000
$\beta_1$	0,0337	0,6845	-1,3210	1,3260
$\beta_2$	0,0581	0,6806	-1,3910	1,2740
$\beta_3$	0,0401	0,2807	-0,5225	0,5934

Entretanto, para fazer a interpretação dos coeficientes é necessário aplicar a função inversa da função de ligação logarítmica, dada por

$$\tilde{y} = \exp(0,0337PM + 0,0581TM + 0,0401URM).$$

Deste modelo, podemos extrair a seguinte interpretação na qual  $\exp(0,0337) = 1,034$  corresponde a um aumento médio de  $(1,034 - 1) \times 100 = 3,4\%$  nos casos de dengue notificados quando se toma por base a precipitação média mensal. Tomando por base a temperatura média, tem-se  $\exp(0,0581) = 1,059$  correspondendo a um aumento médio de  $(1,059 - 1) \times 100 = 5,9\%$ . Por fim, com base na umidade relativa média, tem-se  $\exp(0,0401) = 1,041$  correspondendo a um aumento médio de  $(1,041 - 1) \times 100 = 4,1\%$ .

A Figura 5 apresenta as contagens dos casos de dengue, os valores ajustados e os intervalos a 95% credibilidade. Perceber-se que a série modelada ajusta-se satisfatoriamente a contagem de notificações apesar da alta variabilidade dos dados.

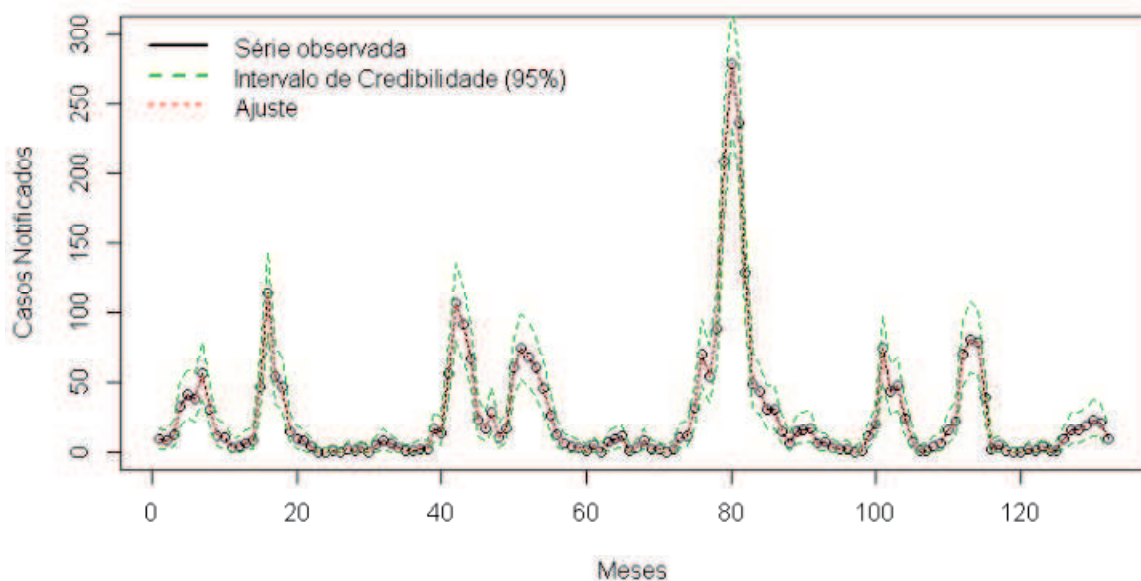


Figura 5 – Ajuste pelo modelo dinâmico de Poisson com as variáveis meteorológicas Precipitação, Temperatura e Umidade.

Na Tabela 5 é apresentada uma previsão para o ano de 2018, contendo os intervalos de credibilidade à 95% . De modo geral, o modelo conseguiu captar um aumento dos períodos de casos notificados no começo do ano, porém houve um aumento exagerado na previsão a partir do quarto mês.

Tabela 5 – Previsão mensal da incidência com os respectivos intervalos de credibilidade à 95%.

Mês	Previsão	2,5%	97,5%
Janeiro	23,5	0	119,0
Fevereiro	37,43	0	252,0
Março	61,08	0	422,0
Abril	103,2	0	822,0
Maiο	170,0	0	1215,0
Junho	328,6	0	1912,0

No artigo publicado de Martínez-Bello, López-Quílez e Torres-Prieto (2017), onde o modelo dinâmico de Poisson foi ajustado a contagem de casos notificados de dengue, os autores comentam que esse modelos de previsão da dengue geralmente registram o comportamento cíclico ou sazonal da série temporal em questão. O problema é que a inclusão de tais componentes, como tendência sazonal por meio de estruturas de séries trigonométricas, deixando o modelo bem mais complexo.

## 4 Considerações Finais

Neste trabalho foi proposto um modelo que é capaz de compreender e descrever o comportamento de série temporal, utilizando a distribuição de Poisson. O modelo é baseado nas metodologias dos MLD's e MLGD's o que nos permitiu fazer as inferências dos parâmetros de forma recursiva utilizando o método de Monte Carlo via Cadeias de Markov (MCMC) para obter aproximações dos momentos das densidades a posterioris dos estados.

O modelo estudado além de mais simples, ainda possibilita o uso de covariáveis que ajudam a modelar a incidência da dengue. Em suma, o modelo tem um desempenho moderado de previsão a curto prazo, sendo portanto uma alternativa para previsão para dados de contagem da dengue.

Na aplicação aos dados de casos notificados de dengue o modelo proposto mostrou um bom ajuste, apesar da alta variabilidade nos dados, e uma previsão com desempenho moderada a curto prazo. Nos meses do período chuvoso, identificou-se uma associação com um aumento na notificação da doença no município de Campina Grande. Para um trabalho futuro, pretende-se incluir um componente de sazonalidade com estrutura de séries trigonométricas e fazer o uso de covariáveis sócio-econômicas com a intenção de aumentar o poder de previsão do modelo.

# Referências

- ANDRADE, B. Silveira de; ANDRADE, M. G.; EHLERS, R. S. Bayesian gamma models for count data. *Communications in Statistics: Case Studies, Data Analysis and Applications*, Taylor & Francis, v. 1, n. 4, p. 192–205, 2015. Citado na página 10.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. *Time Series Analysis: Forecasting and Control*. [S.l.]: Wiley, 2008. ISBN 978-0-470-27284-8. Citado na página 12.
- CONGDON, P. *Bayesian models for categorical data*. [S.l.]: John Wiley & Sons, 2005. Citado na página 18.
- DICKEY, D. A.; FULLER, W. A. Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, Taylor & Francis, v. 74, n. 366a, p. 427–431, 1979. Citado na página 12.
- FERREIRA, A. C.; CHIARAVALLLOTI, F.; MONDINI, A. Dengue em araraquara, sp: epidemiologia, clima e infestação por aedes aegypti. *Rev. Saúde Pública*, Rev. Saúde Pública, v. 52, 2018. Citado na página 10.
- FERREIRA, M. A.; GAMERMAN, D. Dynamic generalized linear models. *BIostatistics-BASEL-*, MARCEL DEKKER INC, v. 5, p. 57–72, 2000. Citado na página 19.
- HOFF, P. D. *A first course in Bayesian statistical methods*. [S.l.]: Springer Science & Business Media, 2009. 173–181 p. P. Citado na página 15.
- HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. *International journal of forecasting*, Elsevier, v. 22, n. 4, p. 679–688, 2006. Citado na página 16.
- INMET. *Instituto Nacional de Meteorologia*. 2018. Acesso em: 02 de agosto de 2018. Disponível em: <<http://www.inmet.gov.br>>. Citado na página 20.
- MARTÍNEZ-BELLO, D. A.; LÓPEZ-QUÍLEZ, A.; TORRES-PRIETO, A. Bayesian dynamic modeling of time series of dengue disease case counts. *PLOS Neglected Tropical Diseases*, Public Library of Science (PLoS), v. 11, n. 7, p. e0005696, jul 2017. Citado 2 vezes nas páginas 10 e 25.
- MARTINEZ, E. Z.; SILVA, E. A. S. da. Predicting the number of cases of dengue infection in ribeirão preto, são paulo state, brazil, using a SARIMA model. *Cadernos de Saúde Pública*, FapUNIFESP (SciELO), v. 27, n. 9, p. 1809–1818, sep 2011. Citado na página 10.
- MORETTIN, P. A.; TOLOI, C. Análise de séries temporais. In: *Análise de séries temporais*. São Paulo: Blucher, 2006. Citado na página 12.
- MOULDER, B. C.; ALGINA, J. Comparison of methods for estimating and testing latent variable interactions. *Structural Equation Modeling*, Taylor & Francis, v. 9, n. 1, p. 1–19, 2002. Citado na página 15.

- NELDER, J. A.; WEDDERBURN, R. W. M. Generalized linear models. *Journal of the Royal Statistical Society. Series A (General)*, JSTOR, v. 135, n. 3, p. 370, 1972. Citado na página 18.
- NTZOUFRAS, I. *Bayesian Modeling Using WinBUGS*. [S.l.]: Wiley, 2009. ISBN 978-0470141144. Citado 2 vezes nas páginas 13 e 14.
- PHILLIPS, P. C.; PERRON, P. Testing for a unit root in time series regression. *Biometrika*, Oxford University Press, v. 75, n. 2, p. 335–346, 1988. Citado na página 12.
- POLE, A.; WEST, M.; HARRISON, J. *Applied Bayesian forecasting and time series analysis*. [S.l.]: Chapman and Hall/CRC, 1994. Citado na página 14.
- R Core Team. *R: A Language and Environment for Statistical Computing*. Vienna, Austria, 2018. Disponível em: <<https://www.R-project.org/>>. Citado na página 23.
- SAÚDE, M. da Saúde (BR) Secretaria de Vigilância em. Monitoramento dos casos de dengue, febre de chikungunya e febre pelo vírus zika até a semana epidemiológica 52, 2015. *Bol Epidemiol*, v. 47, n. 31, p. 1–10, 2016. Citado na página 10.
- STURTZ, S.; LIGGES, U.; GELMAN, A. R2openbugs: A package for running openbugs from r. *Journal of Statistical Software*, v. 12, n. 3, p. 1–16, 2005. Disponível em: <<http://www.jstatsoft.org>>. Citado na página 23.
- TAUIL, P. L. Aspectos críticos do controle do dengue no brasil. *Cadernos de Saúde Pública*, SciELO Brasil, v. 18, n. 3, p. 867–871, 2002. Citado na página 10.
- THOMAS, A.; O'HARA, R. B. *OpenBUGS*. 2004. Citado na página 23.
- TRIANAFYLLOPOULOS, K. Inference of dynamic generalized linear models: on-line computation and appraisal. *International Statistical Review*, Wiley Online Library, v. 77, n. 3, p. 430–450, 2009. Citado na página 18.
- WEST, M.; HARRISON, J. Bayesian forecasting and dynamic models. *Springer New York, New York, NY, USA. Livestock Research Rapport*, v. 897, p. 55, 1997. Citado 3 vezes nas páginas 10, 16 e 18.
- WEST, M.; HARRISON, P. J.; MIGON, H. S. Dynamic generalized linear models and bayesian forecasting. *Journal of the American Statistical Association*, Taylor & Francis Group, v. 80, n. 389, p. 73–83, 1985. Citado 2 vezes nas páginas 11 e 17.

# APÊNDICE A – Modelo Dinâmico de Poisson pelo OpenBUGS

```
model{
  for(t in 1:n){
    y[temp[t]] ~ dpois(nu[t])
    ypred[t] ~ dpois(nu[t])
    log(nu[t]) <- alpha[t]+eta[t]+b1[t]*(chuva[t]-mean(chuva[]))+
    b2[t]*(temp.m[t]-mean(temp.m[]))+b3[t]*(umidade[t]-mean(umidade[]))
    w1[t] ~ dnorm(0, W1)
    eta[t] ~ dnorm(0, W3)
    b1[t] ~ dnorm(0, W4)
    b2[t] ~ dnorm(0, W5)
    b3[t] ~ dnorm(0, W6)
  }
  for(t in 2:n){
    alpha[t] <- alpha[t-1]+ w1[t]
  }
}
```

## APÊNDICE B – Modelo Dinâmico de Poisson pelo R

```
require(R2OpenBUGS)
modelo<-function(){
  for(t in 1:n){
    y[temp[t]] ~ dpois(nu[t])
    ypred[t] ~ dpois(nu[t])
    log(nu[t])<-alpha[t]+eta[t]+b1[t]*(chuva[t]-mean(chuva[]))+
    b2[t]*(temp.m[t]-mean(temp.m[]))+b3[t]*(umidade[t]-mean(umidade[]))
    w1[t] ~ dnorm(0, W1)
    eta[t] ~ dnorm(0, W3)
    b1[t] ~ dnorm(0, W4)
    b2[t] ~ dnorm(0, W5)
    b3[t] ~ dnorm(0, W6)
  }
  for(t in 2:n){
    alpha[t] <- alpha[t-1]+ w1[t]
  }
}
```



## APÊNDICE C – Densidades e interações da simulação dos parâmetros do modelo.

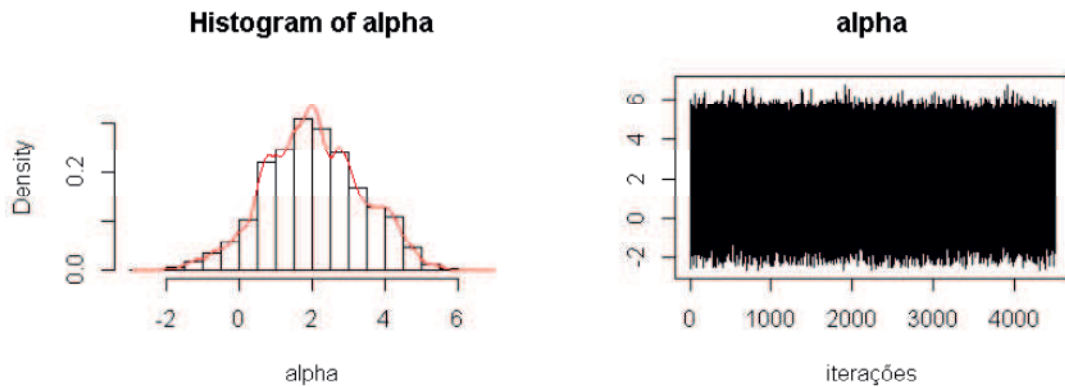


Figura 6 – Desidade e iterações para  $\alpha_t$

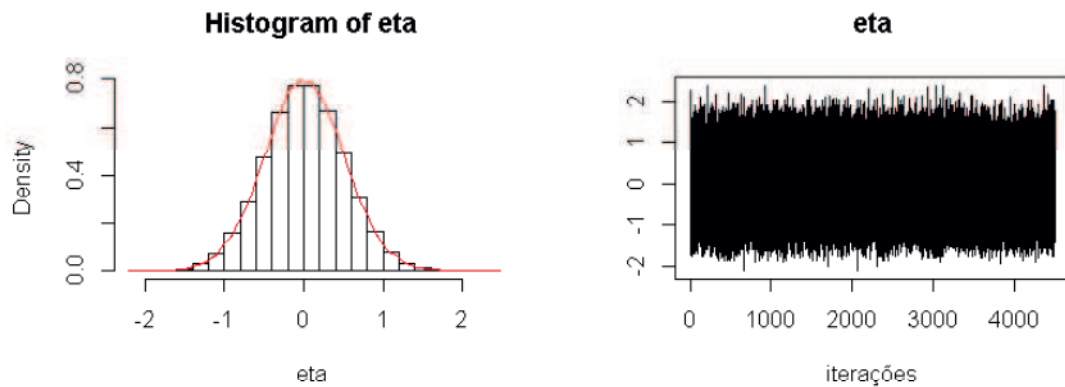


Figura 7 – Desidade e iterações para  $\eta_t$

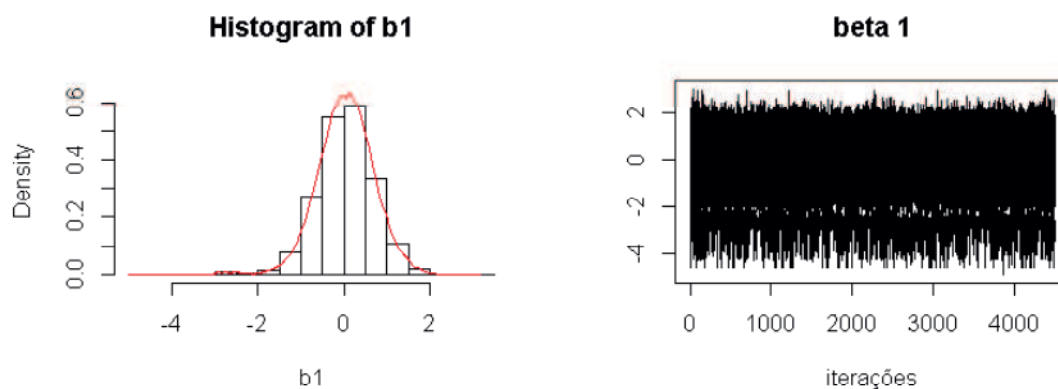


Figura 8 – Densidade e iterações para  $\beta_{1,t}$




Figura 9 – Densidade e iterações para  $\beta_{2,t}$




Figura 10 – Densidade e iterações para  $\beta_{3,t}$