



CAROLINA CRISTINA BICALHO

**ANÁLISE DA INFLUÊNCIA DE FATORES
CLIMÁTICOS NA EPIDEMIA DE DENGUE NAS
CIDADES DE CUIABÁ (MT) e LAVRAS (MG)**

LAVRAS - MG

2011

CAROLINA CRISTINA BICALHO

**ANÁLISE DA INFLUÊNCIA DE FATORES
CLIMÁTICOS NA EPIDEMIA DE DENGUE NAS
CIDADES DE CUIABÁ (MT) e LAVRAS (MG)**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas, área de concentração em Modelagem de Sistemas Biológicos, para a obtenção do título de Mestre.

Dra. Thelma Sáfydi

Orientadora

Dra. Iraziet da Cunha Charret

Coorientadora

LAVRAS - MG

2011

**Ficha Catalográfica Preparada pela Divisão de Processos Técnicos da
Biblioteca da UFLA**

Bicalho, Carolina Cristina.

Análise da influência de fatores climáticos na epidemia de dengue nas cidades de Cuiabá (MT) e Lavras (MG)

Carolina Cristina Bicalho. – Lavras: UFLA, 2011.

139 p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2011.

Orientador: Thelma Sáfyadi.

Bibliografia.

1. Modelos computacionais. 2. Séries temporais. 3. Modelos de regressão. 4. Modelos estatísticos. 5. Clima. I. Universidade Federal de Lavras. II. Título.

CDD - 003.3513

CAROLINA CRISTINA BICALHO

**ANÁLISE DA INFLUÊNCIA DE FATORES
CLIMÁTICOS NA EPIDEMIA DE DENGUE NAS
CIDADES DE CUIABÁ (MT) e LAVRAS (MG)**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas, área de concentração em Modelagem de Sistemas Biológicos, para a obtenção do título de Mestre.

APROVADA em 16 de agosto de 2011.

Dra. Iraziet da Cunha Charret	UFLA
Dr. João Domingos Scalon	UFLA
Dra. Paula Mendes Luz	FIOCRUZ - RJ

Dra. Thelma Sáfadi
Orientadora

LAVRAS - MG

2011

*A meus pais, Antônio e Arlete;
minhas irmãs, Karine e Camila;
e, em especial, meu grande amigo, Crysttian,
DEDICO.*

AGRADECIMENTOS

A Deus, pela força e coragem durante essa longa caminhada.

Arlete e Antônio, pais sempre presentes e imprescindíveis em minha vida, pelo carinho, amor, atenção, educação concedida, zelo, cuidado, orações e torcida por mim!

Minhas irmãs, Karine e Camila, pelo incentivo e amizade.

Minha tia Oneida, pela atenção e carinho.

Ao Crysttian, por todo o companheirismo, pelas sugestões e ajuda durante essa difícil jornada, além da amizade demonstrada, enfim pelo apoio incondicional.

Minhas lindas sobrinhas, Beatriz e Mariana, pelo sorriso e vontade de vencer.

Meus cunhados, Róbson e Geraldo pela amizade.

A querida orientadora e professora Thelma Sáfadi, pelos conselhos, orientações, dedicação e paciência.

A meus amigos do grupo de estudo sobre a dengue, em especial Rosana, Stella, Leila, Silvestre, Renatto e Crysttian por compartilharem dos momentos alegres e das dificuldades.

À professora e amiga Iraziet Charret, aquela que, quando deveria ser simplesmente professora, foi mestre; que quando deveriam ser mestre, foi amiga; e com esta amizade me compreendeu e me incentivou a seguir sempre em frente.

A todos os professores e funcionários dos Departamentos de Engenharia e Exatas, que deram apoio para que o trabalho prosseguisse, obrigada pelo auxílio, presteza e boa vontade.

À CAPES pela concessão de bolsa de estudos.

Às amigas de Bambuí, em especial Murielle, Maria Cristina, Hortência e Josélia.

Aos colegas de curso em Engenharia de Sistemas em especial, Rosana, Stella e Leila, que se tornaram amigas.

A todos os amigos do programa de Pós-Graduação em Estatística e Experimentação Agropecuária pela amizade e ensinamentos.

Às minhas amigas de república, Thais e Iábita, pelo apoio e amizade.

À Universidade Federal de Lavras, que me proporcionou cursar o mestrado em Engenharia de Sistemas.

A todos aqueles, que de alguma forma, acreditaram e contribuíram para a conclusão deste trabalho e realização deste sonho.

Meus sinceros agradecimentos!!!

Ainda que eu falasse as línguas dos homens e dos anjos, e não tivesse amor,

(...) nada seria.

(...) O amor é sofredor, é benigno; o amor não é invejoso;

o amor não se vangloria, não se ensoberbece,

não se porta inconvenientemente,

não busca os seus próprios interesses,

não se irrita, não suspeita mal;

não se regozija com a injustiça, mas se regozija com a verdade;

tudo sofre, tudo crê, tudo espera, tudo suporta.

(...) Agora, pois, permanecem a fé, a esperança, o amor, estes três; mas o maior destes é o AMOR.

Coríntios 13, 1-13

RESUMO

A dengue é um dos principais problemas de saúde pública no mundo. Estima-se que cerca de 2,5 bilhões de pessoas estão agora em risco de dengue. Diante deste contexto atual da doença desenvolvemos um modelo de série temporal na tentativa de identificar os fatores climáticos que contribuem para a proliferação da dengue nas cidades de Lavras (Minas Gerais) e Cuiabá (Mato Grosso). As séries para análise foram o número de casos notificados de dengue, séries de temperatura mínima, média e máxima, umidade relativa do ar e índice pluviométrico da cidade de Lavras e em Cuiabá consideramos as séries do número de casos notificados de dengue e séries de temperatura mínima e máxima e índice pluviométrico. Foram encontrados os modelos que melhores se ajustam aos dados de acordo com a metodologia de Box e Jenkins. O modelo de regressão que consistiu na variável dependente como sendo resíduo de casos de dengue e as variáveis independentes sendo os resíduos dos modelos das variáveis climáticas. Em Cuiabá, a precipitação e a temperatura máxima possuem influência no número de casos de dengue. Já em Lavras, além da precipitação e da temperatura máxima, também influenciaram o número de casos de dengue a temperatura média e a umidade. Os coeficientes de determinação R^2 , em Cuiabá e Lavras foram de R^2 0,31 e R^2 de 0,68, respectivamente. No segundo ajuste para Lavras consideramos as séries de temperatura máxima e mínima e precipitação com um R^2 de 0,67 e a temperatura máxima e a precipitação continuaram a influenciar no número de casos de dengue. Não foi possível propor um único modelo que explicasse o comportamento do número de casos de dengue para as duas cidades. Isto pode estar fortemente relacionado a variabilidade climática. Porém, ambos os modelos possuem um componente comum, que é a influência da temperatura máxima com defasagem de quatro meses.

Palavras-chave: Séries Temporais. Dengue. Clima.

ABSTRACT

Dengue is a major public health problems in world. It is estimated that some 2.5 billion people are now at risk of dengue. Given this current context of disease develop a time series model in attempt to identify the climatic factors contribute to the spread of dengue fever in the cities of Lavras (Minas Gerais) and Cuiabá (Mato Grosso). The series for analysis were the number of reported cases of Dengue, a series of minimum temperature, average and maximum relative humidity and rainfall in the city of Lavras Cuiabá and consider the series of the number of reported cases of dengue and minimum temperature series and maximum rate and found the pluviométrico. We found the models that best fit the data according to Box and Jenkins methodology. The regression model that was the dependent variable as residue dengue cases and the independent variables being the waste of models of climate variables. In Cuiabá, precipitation and maximum temperature have an influence the number of dengue cases. Already in Lavras, in addition to precipitation, maximum temperature, also influenced the number of dengue cases and the average temperature moisture. The coefficients of determination R^2 , in Cuiabá and Lavras were R^2 0.31 and R^2 of 0.68, respectively. In the second set to Lavras consider the series of maximum and minimum temperature and precipitation with a R^2 of 0.67 and the maximum temperature and precipitation continued to influence the number of dengue cases. It was not possible to propose a single model to explain the behavior of the number of cases of dengue for the two cities. This can be strongly related to climate variability. However, both models have a common component, which is the influence of maximum temperature with a delay of four months.

Keywords: Time Series. Dengue. Weather.

LISTA DE FIGURAS

Figura 1	Mapa mundial de risco de dengue no mundo no ano de 2010 . . .	27
Figura 2	Mapa de risco de dengue no Brasil no período de 2010 e 2011 . .	28
Figura 3	Casos notificados de dengue, de acordo com a semana de início dos sintomas e as regiões. Brasil, novembro de 2010 a março de 2011	29
Figura 4	Casos notificados de dengue por semana epidemiológica 1 de 2009 a semana epidemiológica 7 de 2010 nos estados da Região Sudeste	30
Figura 5	Casos notificados de dengue por semana epidemiológica 1 de 2009 a semana epidemiológica 7 de 2010 nos estados da Região Centro-Oeste	31
Figura 6	Mosquito <i>Aedes aegypti</i>	32
Figura 7	Localização da cidade de Lavras (Minas Gerais) e Cuiabá (Mato Grosso)	60
Figura 8	Representação gráfica da série mensal do número de casos de dengue da cidade de Cuiabá, do período de janeiro de 2001 a dezembro de 2009	66
Figura 9	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série do número de casos de dengue da cidade de Cuiabá	67
Figura 10	Gráfico da média x amplitude dos dados da série de casos de dengue da cidade de Cuiabá de 2001 a 2009	68
Figura 11	Série mensal do ln dos casos de dengue da cidade de Cuiabá, do período de janeiro de 2001 a dezembro de 2009	68
Figura 12	Representação das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) do ln da série mensal do número de casos de dengue da cidade de Cuiabá	69
Figura 13	Periodograma de casos de dengue de Cuiabá, do período de janeiro de 2001 a dezembro de 2009	69
Figura 14	Série estacionária casos de dengue de Cuiabá	70
Figura 15	Função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série estacionária casos de dengue de Cuiabá	71
Figura 16	Função de autocorrelação (ACF) e autocorrelação parcial (PACF) do resíduo do modelo ajustado para a série Ln de casos de dengue de Cuiabá	72
Figura 17	Série Temperatura máxima(a), série de temperatura mínima(b), série de precipitação(c) da cidade de Cuiabá no período de janeiro de 2001 a dezembro de 2009	73

Figura 18	Gráfico da normalidade dos resíduos do modelo ajustado de regressão para a cidade de Cuiabá	75
Figura 19	Representação gráfica da série mensal do número de casos de dengue da cidade de Lavras, de janeiro de 2001 a dezembro de 2009	76
Figura 20	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série do número de casos de dengue da cidade de Lavras	76
Figura 21	Gráfico da Média x amplitude dos dados da série de casos de dengue da cidade de Lavras de 2001 a 2009	77
Figura 22	Série mensal do ln dos casos de dengue da cidade de Lavras no período de janeiro de 2001 a dezembro de 2009	77
Figura 23	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série mensal ln do número de casos de dengue da cidade de Lavras	78
Figura 24	Periodograma de casos de dengue de Lavras, no período de janeiro de 2001 a dezembro de 2009	78
Figura 25	Série estacionária casos de dengue de Lavras	79
Figura 26	Gráfico da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série estacionária casos de dengue de Lavras	80
Figura 27	Gráfico da função de autocorrelação (ACF) e autocorrelação parcial (PACF) do resíduo da série Ln de casos de dengue de Lavras	81
Figura 28	Série Temperatura máxima(a), série de temperatura média(b), série de temperatura mínima(c), série de precipitação(d), série de umidade(e) da cidade de Lavras no período de janeiro de 2001 a dezembro de 2009	82
Figura 29	Gráfico da normalidade dos resíduos do modelo ajustado de regressão para a cidade de Lavras	85
Figura 30	Gráfico da normalidade dos resíduos do segundo modelo ajustado de regressão para a cidade de Lavras	86
Figura 31	Representação gráfica da série mensal de temperatura máxima da cidade de Cuiabá, de janeiro de 2001 a dezembro de 2009	98
Figura 32	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série de temperatura máxima da cidade de Cuiabá	99
Figura 33	Média x amplitude dos dados de temperatura máxima da cidade de Cuiabá	99
Figura 34	Periodograma de temperatura máxima de Cuiabá	100
Figura 35	Série estacionária de temperatura máxima de Cuiabá	101

Figura 36	Função de autocorrelação (ACF) da série estacionária de temperatura máxima de Cuiabá	101
Figura 37	Função de autocorrelação do resíduo da série de temperatura máxima de Cuiabá	102
Figura 38	Representação gráfica da série mensal de temperatura mínima da cidade de Cuiabá, de janeiro de 2001 a dezembro de 2009	103
Figura 39	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da temperatura mínima da cidade de Cuiabá	103
Figura 40	Média vs amplitude dos dados de temperatura mínima da cidade de Cuiabá	104
Figura 41	Periodograma de temperatura mínima de Cuiabá	104
Figura 42	Série estacionária de temperatura mínima de Cuiabá	105
Figura 43	Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de temperatura mínima da cidade de Cuiabá	106
Figura 44	Fac e Facp residual do modelo temperatura mínima da cidade de Cuiabá	107
Figura 45	Representação gráfica da série mensal da precipitação da cidade de Cuiabá, de janeiro de 2001 a dezembro de 2010	108
Figura 46	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série de precipitação da cidade de Cuiabá	108
Figura 47	Média vs amplitude dos dados da série de precipitação da cidade de Cuiabá	109
Figura 48	Série mensal do Ln da precipitação da cidade de Cuiabá	109
Figura 49	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série mensal ln da precipitação da cidade de Cuiabá	110
Figura 50	Periodograma da precipitação de Cuiabá	110
Figura 51	<i>Série estacionária da precipitação de Cuiabá</i>	111
Figura 52	Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de precipitação da cidade de Cuiabá	112
Figura 53	Função de autocorrelação e autocorrelação parcial do resíduo da série de precipitação de Cuiabá	113
Figura 54	Representação gráfica da série mensal de temperatura máxima da cidade de Lavras, de janeiro de 2001 a dezembro de 2009	114
Figura 55	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série de temperatura máxima da cidade de Lavras	115
Figura 56	Média vs amplitude dos dados de temperatura máxima da cidade de Lavras	115

Figura 57	Periodograma de temperatura máxima de Lavras	116
Figura 58	Série estacionária de temperatura máxima de Lavras	117
Figura 59	Função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série estacionária de temperatura máxima de Lavras	117
Figura 60	Função de autocorrelação e autocorrelação parcial do resíduo da série de temperatura máxima de Lavras	118
Figura 61	Representação gráfica da série mensal de temperatura média da cidade de Lavras, de janeiro de 2001 a dezembro de 2009	119
Figura 62	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da temperatura média da cidade de Lavras	120
Figura 63	Média vs amplitude dos dados de temperatura média da cidade de Lavras	120
Figura 64	Periodograma de temperatura média da cidade de Lavras	121
Figura 65	Série estacionária de temperatura média da cidade de Lavras	122
Figura 66	Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de temperatura média da cidade de Lavras	122
Figura 67	Função de autocorrelação e autocorrelação parcial do resíduo do modelo da série de temperatura média de Lavras	123
Figura 68	Representação gráfica da série mensal de temperatura mínima da cidade de Lavras, de janeiro de 2001 a dezembro de 2009	124
Figura 69	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da temperatura mínima da cidade de Lavras	124
Figura 70	Média vs amplitude dos dados de temperatura mínima da cidade de Lavras	125
Figura 71	Periodograma de temperatura mínima de Lavras	126
Figura 72	Série estacionária de temperatura mínima de Lavras	127
Figura 73	Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de temperatura mínima da cidade de Lavras	127
Figura 74	Fac e Facp residual do modelo temperatura mínima da cidade de Lavras	128
Figura 75	Representação gráfica da série mensal da precipitação da cidade de Lavras, de janeiro de 2001 a dezembro de 2010	129
Figura 76	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série de precipitação da cidade de Lavras	129
Figura 77	Média x amplitude dos dados da série de precipitação da cidade de Lavras	130
Figura 78	Periodograma da precipitação de Lavras	131
Figura 79	Série estacionária da precipitação de Lavras	131

Figura 80	Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de precipitação da cidade de Lavras	132
Figura 81	Função de autocorrelação e autocorrelação parcial do resíduo da série de precipitação de Lavras	133
Figura 82	Representação gráfica da série mensal da umidade relativa do ar da cidade de Lavras, de janeiro de 2001 a dezembro de 2010 . . .	134
Figura 83	Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série de umidade relativa do ar da cidade de Lavras	134
Figura 84	Média vs amplitude dos dados da série de umidade da cidade de Lavras	135
Figura 85	Periodograma da umidade de Lavras	135
Figura 86	Série estacionária da umidade de Lavras	136
Figura 87	Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de umidade da cidade de Lavras	137
Figura 88	Função de autocorrelação e autocorrelação parcial do resíduo da série de umidade de Lavras	138

LISTA DE TABELAS

Tabela 1	Estimativas dos parâmetros do modelo SARIMA(1,0,0)x(1, 1, 0) ₁₂ e seus respectivos erros padrão e p-valor e o valor de Akaike para série do número de casos de dengue da cidade de Cuiabá - MT .	71
Tabela 2	Modelos encontrados para as séries climática da cidade de Cuiabá-MT	72
Tabela 3	Estimativas dos parâmetros do modelo de regressão para Cuiabá-MT	74
Tabela 4	Estimativas dos parâmetros do modelo SARIMA(7,0,1)x(1, 1, 1) ₁₂ e seus respectivos erros padrão, p-valor e valor de Akaike para série do número de casos de dengue da cidade de Lavras - MG .	80
Tabela 5	Modelos encontrados para as séries climáticas da cidade de Lavras-MG	83
Tabela 6	Estimativas dos parâmetros do modelo de regressão para Lavras-MG	84
Tabela 7	Estimativas dos parâmetros do segundo modelo de regressão para Lavras-MG	85
Tabela 8	Estimativas dos parâmetros do modelo SARIMA(1,0,0)x(0, 1, 1) ₁₂ e seus respectivos erros padrão para série de temperatura máxima da cidade de Cuiabá - MT	102
Tabela 9	Estimativas dos parâmetros do modelo SARIMA(0,0,0)x(0, 1, 1) ₁₂ e seus respectivos erros padrão para série de temperatura mínima da cidade de Cuiabá - MT	106
Tabela 10	Estimativas dos parâmetros do modelo SARIMA(1,0,0)x(0, 1, 1) ₁₂ e seus respectivos erros padrão para série de precipitação da cidade de Cuiabá - MT	112
Tabela 11	Estimativas dos parâmetros do modelo SARIMA(1,0,1)x(2, 1, 0) ₁₂ e seus respectivos erros padrão para série de temperatura máxima da cidade de Lavras - MG	118
Tabela 12	Estimativas dos parâmetros do modelo SARIMA(2,0,1)x(2, 1, 0) ₁₂ e seus respectivos erros padrão para série de temperatura média da cidade de Lavras - MG	123
Tabela 13	Estimativas dos parâmetros do modelo SARIMA(2,0,1)x(2, 1, 0) ₁₂ e seus respectivos erros padrão para série de temperatura mínima da cidade de Lavras - MG	128
Tabela 14	Estimativas dos parâmetros do modelo SARIMA(0,0,1)x(1, 1, 1) ₁₂ e seus respectivos erros padrão para precipitação da cidade de Lavras - MG	132

Tabela 15 Estimativas dos parâmetros do modelo SARIMA(1,0,1)x(1, 1, 1) ₁₂ e seus respectivos erros padrão para série de umidade da cidade de Lavras - MG	137
---	-----

SUMÁRIO

1	INTRODUÇÃO	19
1.1	Considerações iniciais	19
2	REFERENCIAL TEÓRICO	23
2.1	As relações entre o clima e a saúde humana	23
2.2	A dengue	26
2.3	O <i>Aedes aegypti</i>	31
2.4	A incidência de casos de dengue e sua relação com o clima	33
2.5	Séries Temporais - Considerações gerais	34
2.5.1	Tendência	37
2.5.1.1	Teste do Sinal (Cox-Stuart)	37
2.5.2	Sazonalidade	38
2.5.2.1	Periodograma	40
2.5.2.2	Teste de Fisher	40
2.5.3	Função de Autocorrelação	41
2.5.4	Modelos para séries temporais	44
2.5.4.1	Modelo autorregressivo e de médias móveis - ARMA	45
2.5.4.2	Modelos ARIMA	47
2.5.4.3	Modelos ARIMA sazonal - SARIMA	48
2.5.5	Critério para escolha de modelo	49
2.5.5.1	Critério de Akaike	50
2.5.5.2	Mean Absolute Percentage Error - MAPE	50
2.5.6	Teste para resíduo	50
2.6	Modelos de regressão linear	51
2.6.1	Modelos de regressão linear simples	51
2.6.2	Modelos de regressão linear múltipla	52
2.6.2.1	O método de quadrados mínimos	53
2.6.2.2	Coefficiente de determinação - R^2	54
2.6.2.3	Seleção de variáveis regressoras	56
2.6.2.4	Método Backward (passo atrás)	56
2.6.2.5	Análise de resíduos	57
3	MATERIAL E MÉTODOS	60
4	RESULTADOS	66

4.1	Análise das séries temporais climáticas e casos de dengue da cidade de Cuiabá - Mato Grosso	66
4.1.1	Casos de dengue	66
4.1.2	Séries climáticas de Cuiabá	72
4.1.3	Modelo de regressão dos resíduos ajustados para cidade de Cuiabá	73
4.2	Análise das séries temporais climáticas e casos de dengue da cidade de Lavras - Minas Gerais	75
4.2.1	Casos de dengue	75
4.2.2	Séries climáticas de Lavras	81
4.2.3	Modelo de Regressão para cidade de Lavras em Minas Gerais . .	83
5	DISCUSSÃO	87
5.1	Discussão	87
6	CONCLUSÃO	90
	REFERÊNCIAS	92
	APÊNDICE A	98
	APÊNDICE B	114

1 INTRODUÇÃO

1.1 Considerações iniciais

O século passado foi marcado por um forte processo de urbanização, em que a metade da população mundial passou a viver em cidades. Esse crescimento demográfico mundial é fato nítido para a humanidade e trouxe diversas mudanças no meio natural. Dentre elas podem-se citar a redução da fauna e flora, dos mananciais de água potável, o empobrecimento dos solos e as mudanças climáticas, que se fazem sentir na mudança dos regimes de precipitação, umidade, ventos e temperatura em todo o mundo.

Dentre todos os vários problemas ambientais, as mudanças no clima são as que despertam uma maior preocupação. A incidência de determinadas doenças, se relacionam diretamente com a tropicalidade de algumas regiões e zonas climáticas, exatamente por oferecerem condições favoráveis à proliferação de insetos transmissores de doenças.

Neste contexto, o clima afeta a saúde humana de diversas maneiras: furacões, tempestades e inundações matam milhares de pessoas a cada ano e comprometem água e alimentos. As secas provocam fome e desnutrição. Chuvas fortes podem desencadear epidemias de doenças como a malária e a dengue.

Diante disso a dengue é um dos principais problemas de saúde pública no mundo. De acordo com a Organização Mundial da Saúde (OMS) estima-se que cerca de 2,5 bilhões de pessoas estão agora em risco de dengue. A OMS calcula que pode haver 50 milhões de infecções de dengue em todo o mundo a cada ano. A doença é agora endêmica em mais de 100 países na África, Américas, Mediterrâneo Oriental, Sudeste Asiático e no Pacífico Ocidental.

Dentre as doenças reincidentes no Brasil, a dengue destaca-se atualmente

como sendo a mais importante arbovirose ¹ que afeta o homem, principalmente nas regiões de clima tropical e fortemente relacionada com a ineficácia das políticas públicas de saúde, favorecendo o desenvolvimento e a proliferação do *Aedes aegypti*, principal mosquito vetor da dengue.

Até o dia 02 de julho de 2011 foram notificados pela secretaria de vigilância em Saúde 715.666 casos de dengue em todo o país. Deste total, 10.840 são de casos graves e já ocorreram 1102 óbitos suspeitos.

Devido à dimensão do problema descrito, medidas que evitem epidemias de dengue são essenciais em nosso país e no mundo. Para isso, é necessário prever com certa antecedência, ou detectar em um estágio inicial, a ocorrência de uma epidemia. Com isso, medidas de controle mais severas poderiam ser adotadas pelos órgãos de saúde, o que pode implicar em uma drástica redução do número de pessoas acometidas pela doença. Ressalta-se que a previsão de incidência de epidemias e a adoção de medidas de controle acarretam reduções significativas de gastos com saúde e, ainda mais importante, a redução da taxa de mortalidade causada pelas doenças.

É neste cenário que aplicações de computadores em sistemas de vigilância de eventos relacionados à saúde pública, como, por exemplo, o acompanhamento e previsão de epidemias, torna-se essencial. Quer seja para simulações numéricas de modelos matemáticos da dinâmica de disseminação da doença, quer seja para a previsão da incidência e evolução da doença através do uso de séries temporais e métodos computacionais apropriados, um dos temas desta pesquisa.

Diante deste contexto instituições de ensino e pesquisa do Brasil se uniram ao Programa de Apoio aos Núcleos de Excelência (PRONEX - Dengue) com o objetivo de desenvolver modelos, sejam estes estatísticos, mecanicistas (sistemas

¹O termo arbovirose deriva da expressão inglesa "ARthrop BORne VIRUSES" adotada em 1942, para designar doença viral transmitida por artrópodes.

dinâmicos, sistemas complexos) ou computacionais, para avaliar o impacto econômico, epidemiológico e ambiental de estratégias tradicionais e alternativas de monitoramento e controle do risco de transmissão de dengue, assim como gerar algoritmos que facilitem a implementação e acompanhamento das estratégias escolhidas.

Os trabalhos deste grupo foram divididos em:

- análise do padrão espaço-temporal de infestação por *Aedes aegypti* medido com armadilhas. Equipes responsáveis: Universidade Federal de Minas Gerais (UFMG), Fundação Osvaldo Cruz (Fiocruz);
- desenvolvimento de modelos matemáticos georeferenciados que simulem a dinâmica de oviposição dos mosquitos e sua captura por armadilhas. Equipes responsáveis: Universidade Federal de Ouro Preto (UFOP) e Fiocruz;
- avaliação econômica (custo-efetividade) das estratégias de controle vetorial: Equipes responsáveis: Fiocruz, Fundação Getúlio Vargas (FGV);
- desenvolvimento de um aplicativo georeferenciado web para entrada rápida de dados de armadilhas e identificação de áreas prioritárias para controle. Equipes responsáveis: UFOP, Universidade Estadual do Oeste do Paraná (UniOeste), FGV;
- avaliação das condições de utilização de intervenções com base em procedimentos genéticos. Equipes responsáveis: Fiocruz;
- desenvolvimento de modelos que simulem estratégias de intervenção baseadas em controle biológico: Equipes responsáveis: Universidade Federal de Lavras (UFLA), Fiocruz, UniOeste;

- desenvolvimento de modelos matemáticos para avaliar estratégias de controle relacionadas com a dinâmica populacional dos humanos, seu padrão de mobilidade e de atividade. Equipes responsáveis: Fiocruz, UFLA;
- avaliação de estratégias de campanhas vacinais para dengue. Equipes responsáveis: Fiocruz, FGV;

Na Universidade Federal de Lavras destacam-se os trabalhos de iniciação científica, mestrado e doutorado que estão relacionados com autômatos celulares, estatística espacial, modelos utilizando equações diferenciais, regressão e séries temporais.

Contudo, objetiva-se desenvolver um modelo de série temporal e regressão na tentativa de identificar os fatores climáticos que contribuem para a proliferação da dengue nas cidades de Lavras (Minas Gerais) e Cuiabá (Mato Grosso).

Este trabalho está organizado da seguinte maneira: na Seção 1 foi feita uma breve introdução, com a contextualização do assunto e apresentação dos motivos que induziram à realização do trabalho bem como seus objetivos.

Na Seção 2 tem-se uma visão geral da dengue, a doença foco deste trabalho e são apresentados também o embasamento teórico sobre o qual se dará seu desenvolvimento, a relação existente entre o clima e a saúde humana e, ainda, uma abordagem sobre alguns aspectos da análise de séries temporais e regressão.

A metodologia adotada para o estudo é apresentada e descrita na Seção 3. Em seguida, têm-se os resultados e discussão e a conclusão apresentados nas seções 4 e 5, respectivamente.

2 REFERENCIAL TEÓRICO

Nessa seção são sistematizadas as informações inerentes à temática abordada no estudo, com uma visão geral da doença, e a importância do clima no processo de transmissão da dengue. São apresentados também os aspectos teóricos envolvidos nas análises de séries temporais e regressão.

2.1 As relações entre o clima e a saúde humana

O clima é um dos elementos do ambiente que mais influencia o homem. A partir do século XIX, as preocupações em estudar o clima foram intensificadas, devido ao fenômeno de urbanização e do conseqüente crescimento desenfreado do contingente populacional, o que gerou a criação de ambientes urbanos afetando a qualidade de vida das pessoas em vários aspectos, desde o stress urbano até a deterioração dos recursos naturais e o desconforto ambiental, em especial, o térmico (BRANDÃO; RUSSO, 2002).

O estudo da influência das condições atmosféricas na saúde humana é um campo de investigação desde a antiguidade. O primeiro estudo foi realizado por Hipócrates em 460 a.C. Ele escreveu, ao todo, 72 livros, sendo o livro mais importante, a obra intitulada *Ares, água e lugares*, que já apresentava uma tentativa de relacionar a sobrevivência do homem a fatores climáticos.

Com a crescente preocupação em minimizar a calamidade causada pelo "inchaço" das cidades, muitos trabalhos têm sido realizados abordando as relações entre o clima e o homem e os efeitos que um pode causar sobre o outro.

Segundo Lombardo (1985) a urbanização supõe a substituição dos ecossistemas naturais por centros com grandes densidades populacionais criados pelo homem, onde a espécie predominante é o homem e o meio está organizado para

permitir sua sobrevivência. Tais modificações, atreladas ao aumento complexo e caótico do aglomerado populacional, formado por casas, edifícios, ruas, avenidas e um conseqüente aumento dos problemas sociais e ambientais, desencadeiam um crescimento acelerado de necessidades básicas e coletivas como saneamento básico, saúde, transporte, moradia, etc., o que, na maioria das vezes, acarreta uma série de problemas para o homem, sobretudo na área da saúde.

Alguns elementos do clima que afetam diretamente as funções fisiológicas do homem são radiação, temperatura, umidade, vento e pressão atmosférica. O conforto fisiológico do homem é determinado principalmente pela temperatura, pelo vento e pela umidade. As condições e/ou alterações do meio natural só têm importância para o homem quando passam a ser por ele percebidas ou quando afetam ao seu bem estar e ao seu modo de vida (AYOADE,1986).

Conforme Sant'anna Neto (1998), a preocupação do homem com os fenômenos originados na atmosfera e que repercutem na superfície terrestre é tão antiga quanto a sua própria percepção do ambiente. É do ponto de vista da percepção, da forma como o homem percebe e interage com o meio ambiente, em função de influências históricas e socioculturais, que se podem avaliar as necessidades, os interesses e anseios da população, para fornecer aos órgãos dirigentes orientações mais adequadas para as descrições em nível político, socioeconômico e de desenvolvimento, seja rural, urbano ou regional.

Hellpach (1967, p.14) considerou também que a natureza representa um fator muito significativo no desenvolvimento humano, ou seja:

A natureza em torno de nós apresenta-se ao corpo e a alma sobre quatro principais modos fenomênicos: tempo, clima, solo e paisagem, todos influenciam diretamente nosso ser. Na medida em que oferecem ou recomendam esta ou aquela alimentação, nos força a um determinado modo de vestir. [...] As influências meteorológicas não atingem da mesma forma todos os homens. Até mesmo as pessoas de idênti-

cos ambientes de vida, de mesma idade, da mesma raça ou família reagem de modo muito diverso. Estudos realizados comprovaram que na França e Itália, os estupros, suicídios e doenças mentais aumentam consideravelmente no verão.

Na Alemanha, estudos mostraram que quando a pressão atmosférica está baixa o tempo entre as ações e reações físicas aumenta. É o mesmo que acontece com acidentes de trânsito. Observou-se que há maior quantidade de acidentes em dias de alta temperatura e ar úmido e durante a passagem de frentes frias ou oclusas. E as gripes costumam desenvolver-se mais intensamente sob alta pressão e umidade relativa inferior a 50%, com ventos fracos (SCHMIDT, 1994).

Um trabalho realizado na Tailândia estudou a importância de vários fatores climáticos, ambientais e socioeconômicos na previsão de casos de dengue. Para isso, os autores utilizaram modelos estatísticos baseados em funções lineares para obtenção e análise dos resultados (NAKHAPAKORN et al, 2005).

As doenças transmitidas por vetores constituem importante causa de morbidade e mortalidade no Brasil e no mundo. O ciclo de vida dos vetores, assim como dos reservatórios e hospedeiros que participam da cadeia de transmissão de doenças, está fortemente relacionado à dinâmica ambiental dos ecossistemas onde estes vivem. Dentre essas doenças destaca-se a dengue, que é considerada a principal doença reemergente nos países tropicais e subtropicais. Muito se tem especulado sobre a importância de fatores climáticos e variáveis socioeconômicas sobre a incidência da dengue como ferramenta auxiliar na tomada de decisão por parte dos órgãos públicos competentes.

2.2 A dengue

Segundo Gubler (1998) e Teixeira et.al. (1999), o relato mais antigo de doenças com sintomas semelhantes aos da dengue, são os de uma enciclopédia chinesa de *Sintomas de doenças e remédios* publicados durante a dinastia Chin (265 a 420 d.C.) e finalmente editadas em 610 d.C. na dinastia Tang e reeditadas em 992 d.C (dinastia Sung do Norte). A doença era associada pelos chineses aos insetos voadores ligados à água.

Os primeiros relatos sobre dengue no mundo mencionam a Ilha de Java em 1779. Posteriormente, ocorreram casos nas Américas, com epidemias no Caribe e nos Estados Unidos. No século XIX há referência a epidemias ocorridas no Caribe e na Austrália. Também várias epidemias ocorreram no século XX na Europa, África e Américas. No Brasil, há referências de epidemias por dengue na cidade de Niterói (RJ), em 1923, mas sem confirmação laboratorial (MINISTÉRIO DA SAÚDE, 2001). A Figura 1 mostra os países com risco de dengue no mundo no ano de 2010.

A dengue só foi reconhecida como doença no final do século XX e início do século XXI, apesar de ter sido relatada nas Américas há mais de 200 anos, conforme Organização Mundial de Saúde (1987, p.9):

A forma clássica da dengue é uma doença febril aguda acompanhada por cefaléia e dores musculares e articulares. Nas áreas tropicais das regiões do Sudeste Asiático e do Pacífico Ocidental é conhecida há mais de um século. Entretanto, a forma hemorrágica foi inicialmente identificada como uma doença nova nas Filipinas em 1953 (febre hemorrágica das Filipinas) e na Tailândia em 1958 (febre hemorrágica tailândesa). Esses surtos causaram pânico devido à novidade. O mistério do agente causal foi resolvido quando os vírus tipos 2,3,4 foram isolados nas Filipinas, em 1956 e o vírus tipo 1 na Tailândia em 1958.

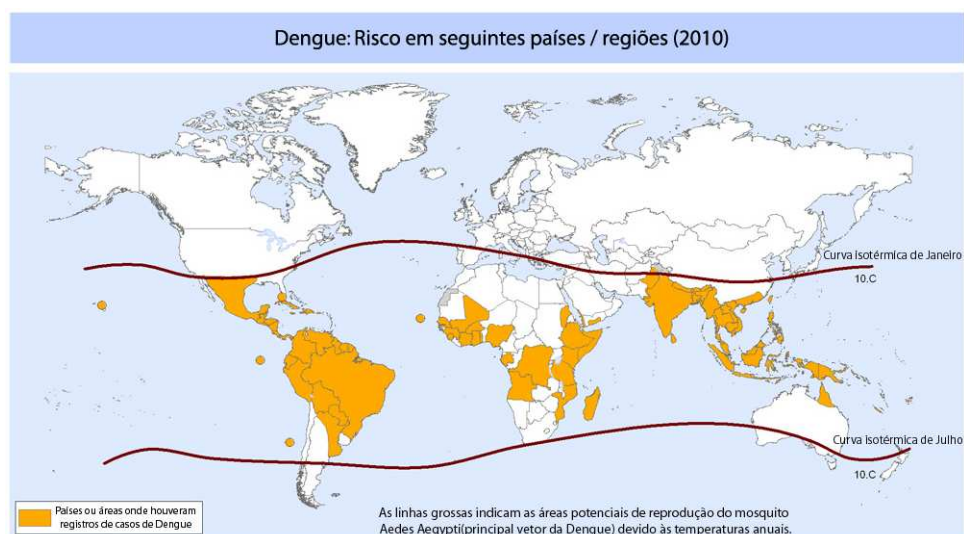


Figura 1 Mapa mundial de risco de dengue no mundo no ano de 2010

Fonte: World Health Organization (2010)

Atualmente, a dengue é considerada a arbovirose humana mais difundida no mundo. Os arbovírus multiplicam-se nos tecidos dos organismos dos artrópodes, que se infectam, tornando-se vetores depois de sugarem o sangue de hospedeiros, em período de viremia (HALSTEAD, 2007).

É uma doença febril aguda causada pelos vírus Dengue (DENV), um arbovírus pertencente à família *Flaviviridae*, gênero *Flavivirus*, com quatro sorotipos distintos, DENV-1, DENV-2, DENV-3 e DENV-4. Estes vírus são transmitidos ao homem por mosquitos do gênero *Aedes*, tendo como principal vetor o *Aedes aegypti*. A transmissão do vírus, em sua forma simples, envolve a ingestão pelo mosquito, de sangue contendo o vírus, e a sua passagem para um segundo hospedeiro humano susceptível (GUBLER, 1995).

As espécies de *Aedes*, transmissor de dengue e febre amarela urbana, são, provavelmente, originárias da África Tropical, tendo sido introduzidas nas Américas durante a colonização, onde se adaptaram como mosquitos urbano e doméstico.

Assim, o mosquito tem sido reintroduzido frequentemente em áreas de onde havia sido erradicado (REY, 1991).

A primeira epidemia com confirmação laboratorial de dengue no Brasil foi em 1982, em Boa Vista (RR). A partir de 1986, vários estados brasileiros registraram ocorrência de picos epidêmicos. O Rio de Janeiro registrou 95.000 casos notificados e aproximadamente 3 milhões de infectados (FIGUEIREDO et.al. 1990; SCHATZMAYR et. al. 1986). Nos últimos 20 anos têm ocorrido diversas epidemias de dengue em todas as regiões do Brasil devido a disseminação do vírus e do vetor transmissor. A Figura 2 mostra o mapa de risco da doença no Brasil em 2010 e 2011.

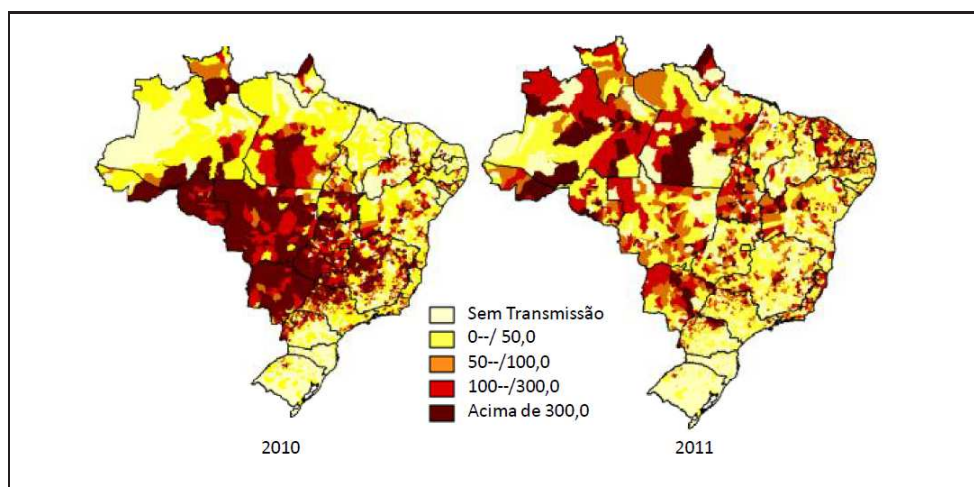


Figura 2 Mapa de risco de dengue no Brasil no período de 2010 e 2011

Fonte: Ministério da saúde (2011)

Várias espécies de mosquitos do gênero *Aedes* podem servir como agente transmissor do vírus do dengue. No Brasil duas delas estão hoje instaladas: *Aedes aegypti* e *Aedes albopictus* (MINISTÉRIO DA SAÚDE, 2001).

A Secretaria de Vigilância em Saúde, em trabalho conjunto com as Secretarias Municipais e Estaduais de Saúde, registrou no ano de 2011 no Brasil 715.666

casos notificados de dengue até o período de janeiro a 02 de julho de 2011. A distribuição dos casos notificados de acordo com as regiões do país é a seguinte: A região Sudeste tem o maior número de casos notificados (338.307 casos; 47%), seguida da Região Nordeste (157.297 casos; 22%), Norte (110.711 casos; 15%), Sul (56.930 casos; 8%) e Centro-Oeste (52.421 casos; 7%). Na análise comparativa em relação ao ano de 2010 observa-se redução de casos nas regiões Sudeste (-25%), Centro Oeste (-74%) e aumento nas regiões Norte (65%), Nordeste (35%) e Sul. (43%)

A Figura 3 apresenta os casos notificados de dengue entre novembro de 2010 e março de 2011 no Brasil de acordo com as regiões do país. Uma tendência de aumento no número de casos é observada a partir do início do ano de 2011, em todas as regiões.




Figura 3 Casos notificados de dengue, de acordo com a semana de início dos sintomas e as regiões. Brasil, novembro de 2010 a março de 2011

Fonte: Ministério da saúde (2011)

Nas sete primeiras semanas epidemiológicas de 2010, a Região Sudeste notificou 38.971 casos, dos quais 27.738 (71,2%) se concentraram em Minas Gerais, seguidos de São Paulo (7.353; 18,9%), Espírito Santo (2.076;5,3%) e Rio de

Janeiro (1.804; 4,6%). A figura 4 mostra graficamente esta situação.




Figura 4 Casos notificados de dengue por semana epidemiológica 1 de 2009 a semana epidemiológica 7 de 2010 nos estados da Região Sudeste

Fonte: Ministério da saúde (2011)

Os estados da região Centro-Oeste apresentam um aumento de casos a partir da semana 41/2009 e, até a sétima semana epidemiológica de 2010, 75.592 casos foram notificados. O Mato Grosso notificou 15.362 casos nas sete primeiras semanas de 2010, com destaque para os municípios de Rondonópolis (1.474; 9,6%), Sinop (1.440; 9,4%), Cuiabá (1.367; 8,9%), Primavera do Leste (1.323; 8,6%), Várzea Grande (802; 5,2%) e Barra do Garças (786; 5,1%). (Figura 5).

Atualmente, sabe-se que ainda não existe uma vacina capaz de imunizar as populações humanas contra as infecções causadas pelo vírus da dengue, devido a sua complexidade, mas esta encontra-se em fase de estudos e desenvolvimento (DONALISIO, 1999). Assim sendo, as intervenções são direcionadas para a redução do mosquito *Aedes aegypti*, através de controle químico e campanhas educativas para a diminuição do número de criadouros. Este combate, para ser efetivo, necessita da participação da comunidade e da alteração de certos hábitos.

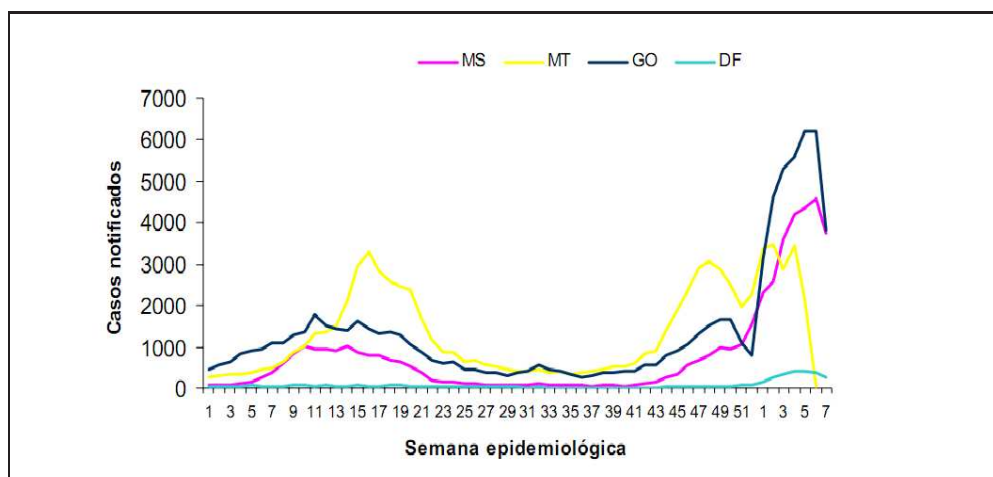


Figura 5 Casos notificados de dengue por semana epidemiológica 1 de 2009 a semana epidemiológica 7 de 2010 nos estados da Região Centro-Oeste

Fonte: Ministério da saúde (2011)

2.3 O *Aedes aegypti*

O *Aedes aegypti* é um mosquito da família *Culicidae*. Os mosquitos adultos podem ser reconhecidos pela nervação da asa característica, pelas escamas ao longo das nervuras e pela longa tromba (Figura 6). Provavelmente tem sua origem na África, onde existem formas silvestres e domésticas. Ele é encontrado, principalmente, no meio urbano, em depósitos de armazenamento de água, sendo considerado essencialmente um mosquito urbano (BORROR; DELONG, 1969).

É uma espécie que se encontra em todo o mundo; distribui-se nas regiões tropicais e subtropicais, em geral limitado às latitudes 45° Norte e 35° Sul, sendo limitado também pela altitude. Em geral, não se encontram acima dos 1000 metros (ORGANIZAÇÃO MUNDIAL DA SAÚDE, 1987). Ele se alimenta da seiva das plantas e, quando as fêmeas estão em fase de maturação dos ovos, fazem repasto sanguíneo, preferencialmente em humanos.

Esse inseto põe seus ovos em qualquer tipo de recipiente que acumule água



Figura 6 Mosquito *Aedes aegypti*
Fonte: Ministério da saúde (2011)

limpa, como calhas e caixa de água, garrafas, pneus, potes, latas e vasos de flores.

Segundo o Centro de informações para viajantes (2001), todas as pessoas podem contrair dengue, independentemente do sexo e idade. Observa-se que as mulheres são mais afetadas, talvez em razão do maior tempo de permanência no ambiente doméstico.

Durante a incubação extrínseca nesse vetor, isto é, durante o período compreendido entre a alimentação infectante e a transmissão pela picada, o vírus se multiplica e atinge as glândulas salivares do artrópode, que por sua vez, transfere o vírus ao homem quando nele se alimenta, fechando o ciclo. Esse período de incubação extrínseca pode variar de 8 a 10 dias (MINISTÉRIO DA SAÚDE, 2005).

Ressalta-se que a transmissão mecânica também é possível, quando o repasto é interrompido e o mosquito, imediatamente, se alimenta num hospedeiro susceptível próximo. Não há transmissão por contato direto de um doente ou de suas secreções com uma pessoa sadia, nem por fontes de água ou alimento (MINISTÉRIO DA SAÚDE, 2005).

2.4 A incidência de casos de dengue e sua relação com o clima

Das pessoas infectadas com dengue, cerca de 550 mil necessitam de hospitalização e pelo menos 20 mil morrem da doença (CUPOLLILLO et al, 2000).

Geralmente é observado um padrão sazonal de incidência da dengue no Brasil, coincidente com o verão, em virtude da maior ocorrência de chuvas e do aumento da temperatura nessa estação, fatores que favorecem o aumento dos índices de infestação e da densidade vetorial. Apesar disso, surtos de dengue também podem ocorrer durante o período seco, e podem estar relacionados, ou não, com a elevação da população do vetor (GUBLER, 1997; HALSTEAD, 1997).

Desse modo, a umidade e a temperatura do ambiente têm efeito sobre a transmissão do vírus. Durante a estação chuvosa, devido à alta umidade, a sobrevivência do mosquito é mais longa. Apesar de que, em algumas regiões, os mosquitos são mais abundantes na estação seca, quando ocorrem chuvas rápidas e esparsas. A formação de pequenas coleções de água favorece a eclosão dos ovos dessecados e o rápido aumento da forma adulta do mosquito (RODHAIN; ROSEN, 1997).

A oviposição do *Aedes aegypti* é feita em recipientes onde existe água, ou recipientes com água de chuva que eventualmente ficam com água por vários dias, o que relaciona a dengue com dias chuvosos. A fêmea deposita seus ovos na borda da lâmina de água. O contato com a água vai ocasionar a eclosão desses ovos (GUBLER, 1997).

O tempo necessário para que o vírus ingerido alcance a glândula salivar do mosquito varia com a temperatura, e é uma importante variável no desencadeamento da transmissão epidêmica. A temperatura alta encurta o período de incubação do vírus no mosquito, que em geral, é de 8 a 12 dias. A temperatura pode também afetar a maturação dos mosquitos; altas temperaturas produzem fêmeas menores que são forçadas a se alimentar um maior número de vezes para ingerir

um volume de sangue necessário para obter a proteína usada para a maturação dos ovos. Isto tem efeito no aumento do número de indivíduos infectados por uma única fêmea e também na capacidade vetorial do mosquito (KUNO, 1998).

As causas da influência do tempo e do clima estão longe de serem totalmente conhecidas. Logo, é de grande importância a elaboração de modelos relacionando clima e saúde humana, pois esta é uma área de crescente preocupação por parte de médicos e climatologistas (GLASSER, 1997).

2.5 Séries Temporais - Considerações gerais

Segundo Morettin e Tolo (2006), uma série temporal pode ser definida como qualquer conjunto de observações tomadas sequencialmente no tempo, podendo ser discretas como, por exemplo, valores mensais de temperatura na cidade de Lavras - MG, ou séries contínuas, como o registro de um eletrocardiograma.

A análise da série temporal pode ser feita no domínio do tempo ou no domínio de frequência, sendo os modelos propostos, paramétricos (com número finito de parâmetros) e não-paramétricos, respectivamente (MORETTIN; TOLOI, 2006). No domínio da frequência tem-se a chamada análise espectral, que possui aplicação em diversas áreas do conhecimento como, por exemplo a medicina.

O objetivo da análise em séries temporais é construir modelos para a série, com propósitos determinados, tais como descrever apenas o comportamento da série, investigar o mecanismo gerador da série temporal, fazer previsão de valores futuros e procurar periodicidades relevantes nos dados.

Um modelo clássico para séries temporais supõe que a série $\{Z_1, \dots, Z_n\}$ pode ser escrita como:

$$Z_t = T_t + S_t + a_t \quad t = 1, 2, \dots, n \quad (1)$$

em que Z_t é a série temporal, T_t é a tendência, S_t é a sazonalidade e a_t é um componente aleatório.

Ainda, segundo Morettin e Toloi (2006), a tendência pode ser entendida como aumento ou diminuição gradual das observações ao longo do período; a sazonalidade mostra flutuações ocorridas em períodos menores ou iguais a doze meses e a componente aleatória mostra oscilações aleatórias irregulares. A suposição usual é a de que a_t seja uma série puramente aleatória ou um ruído branco independente, isto é, tenha média igual a zero e variância constante.

A estimação da tendência e da sazonalidade permite obter a série ajustada para a tendência e sazonalidade ou livre de tendência e sazonalidade. Isto é, representa a chamada condição de estacionariedade, em que a série se desenvolve aleatoriamente no tempo em torno de uma média constante.

A maioria das técnicas estatísticas utilizadas na análise de séries temporais partem do pressuposto de que a série é estacionária. Contudo, se a série não for estacionária, será necessário transformar os dados originais.

O procedimento mais simples utilizado para tornar uma série temporal estacionária consiste em tomar diferenças consecutivas na série original até obter uma série estacionária. Normalmente, uma ou duas diferenças são suficientes para retirar a tendência. Para retirar a sazonalidade deve-se fazer uma diferença com *lag* do tamanho da periodicidade da série em estudo.

A primeira diferença é definida por:

$$\Delta Z_t = Z_t - Z_{t-1} \quad t = 1, 2, \dots, n \quad (2)$$

A segunda diferença é dada

$$\begin{aligned}
 \Delta^2 Z_t &= \Delta(\Delta Z_t) \\
 &= \Delta(Z_t - Z_{t-1}) \\
 &= Z_t - Z_{t-1} - (Z_{t-1} - Z_{t-2}) \\
 &= Z_t - 2Z_{t-1} + Z_{t-2} \quad t = 1, 2, \dots, n
 \end{aligned} \tag{3}$$

Generalizando, a n-ésima diferença é

$$\Delta^n Z_t = \Delta \{ \Delta^{n-1} Z_t \} \quad t = 1, 2, \dots, n \tag{4}$$

Em algumas séries poderá ser necessário aplicar uma transformação não linear, como a logarítmica, para estabilizar a variância e tornar o efeito sazonal aditivo. Esta transformação deverá ser aplicada à série original.

Para verificar a necessidade de se fazer uma transformação utiliza-se o gráfico que apresenta a média dos dados no eixo das abscissas e a amplitude no eixo das ordenadas. Para o cálculo da média e amplitude, a série original deverá ser dividida em subconjuntos. Se o gráfico mostrar pontos espalhados em torno de uma reta paralela ao eixo das abscissas, isto é uma indicação de que não será necessário fazer uma transformação. Porém, se a amplitude for diretamente proporcional à média, isto seria um indicativo de que a transformação logarítmica é adequada (MORETTIN; TOLOI, 2006).

2.5.1 Tendência

Supondo-se a ausência de sazonalidade, tem-se o modelo

$$Z_t = T_t + a_t \quad t = 1, 2, \dots, n \quad (5)$$

em que a_t é um ruído branco. Existem vários métodos para estimar a tendência, dentre eles, o ajuste polinomial e suavização (filtro), vistos em Morettin e Tolo (2006).

Estimando-se a tendência \hat{T}_t , a série pode ser escrita livre de tendência como

$$Y_t = Z_t - \hat{T}_t \quad t = 1, 2, \dots, n \quad (6)$$

Outro procedimento para eliminar a tendência de uma série é tomar a diferença, como foi definido pelas equações 2 e 3.

Pela análise visual pode-se avaliar se uma série temporal possui tendência. No entanto, para confirmar essa avaliação prévia, dois procedimentos são utilizados: análise do gráfico da autocorrelação e um teste de tendência. Dentre esses testes descritos em Morettin e Tolo (2006), apresentamos o teste do Sinal (Cox-Stuart).

2.5.1.1 Teste do Sinal (Cox-Stuart)

A fim de verificar a existência de tendência na série temporal aconselha-se fazer o teste para verificar se existe a componente de tendência na série antes de se aplicar qualquer procedimento para sua estimação.

O procedimento para aplicar o teste do sinal é o seguinte:

1. agrupam-se as observações em pares $(Z_1, Z_{c+1}), (Z_2, Z_{c+2}), (Z_{N-c}, Z_N)$,

em que $c = N/2$ se N , números de observações for par, e $c = (N + 1)/2$ se N for ímpar;

2. para cada par (Z_1, Z_{c+1}) , associa-se um sinal. Este sinal é positivo (+) se $Z_i < Z_{c+i}$ e negativo(-) se $Z_i > Z_{c+i}$. Descarta-se a comparação se $Z_i = Z_{c+i}$, onde T é igual ao número de pares com sinal de positivo (+).
3. testa-se a hipótese de nulidade.

$$\begin{aligned} H_0 & : P(Z_i < Z_{i+c}) = P(Z_i > Z_{i+c}), \quad \forall i : \text{não existe tendência;} \\ H_1 & : P(Z_i < Z_{i+c}) \neq P(Z_i > Z_{i+c}), \quad \forall i : \text{existe tendência;} \quad (7) \end{aligned}$$

4. Calcula-se o valor de t , que é dado por:

$$t = \frac{1}{2}(n + \omega_{\alpha/2}\sqrt{n}) \quad (8)$$

em que n é o número de vezes que não houve empate na comparação entre Z_i e Z_{c+i} e $\omega_{\alpha/2}$ é o valor tabelado ao nível de significância α . Caso $n \leq 20$, o valor tabelado de $\omega_{\alpha/2}$ é dado pela distribuição binomial com $p = 0,5$ e, caso $n > 20$, utiliza-se a distribuição normal;

5. se $T \leq t$ ou $T \geq n - t$, rejeita H_0 , isto é, a série possui tendência.

2.5.2 Sazonalidade

A componente sazonal capta características da série que ocorrem regularmente dentro do período de um ano, isto é, os fenômenos sazonais ocorrem regularmente em período de no máximo doze meses. O que se observa em séries sazonais de período 12 é que ocorrem as seguintes relações:

- i. entre meses sucessivos, em um ano particular;
- ii. entre observações para o mesmo mês, em anos consecutivos.

De maneira geral, pode-se afirmar que as séries sazonais apresentam alta correlação em *lags* sazonais. Os procedimentos mais comuns para se estimar a sazonalidade são o método de regressão (sazonalidade determinística) e o método de médias móveis (sazonalidade estocástica), visto em Morettin e Toloi (2006).

Estimada a sazonalidade \hat{S}_t , a série pode ser escrita livre da componente sazonal. Se o modelo da série for aditivo, onde o padrão sazonal não se altera à medida que o nível da série muda, tem-se:

$$Z_t^{SA} = Z_t - \hat{S}_t \quad t = 1, 2, \dots, n \quad (9)$$

e se for multiplicativo em que a sazonalidade da série é afetada pelo nível da mesma, tem-se:

$$Z_t^{SA} = Z_t / \hat{S}_t \quad t = 1, 2, \dots, n \quad (10)$$

Toda periodicidade acima do período de 12 meses é considerada ciclo. Retirando-se o efeito do ciclo, a série perde muitas observações, reduzindo seu tamanho, o que prejudica e dificulta o ajuste do modelo.

A construção do gráfico é essencial nas análises de séries temporais, visto que ele revela características importantes, tais como tendência, sazonalidade, variabilidade e *outliers* que são observações periféricas, ou aberrantes, e são aqueles que parecem desviar-se acentuadamente a partir de outros membros da amostra em que ocorrem. No entanto, a inspeção visual é subjetiva. Existem testes de hipóteses estatísticos para verificar a presença das componentes tendência e sazonalidade.

A seguir será descrita a análise gráfica do periodograma e dentre vários testes para sazonalidade apresenta-se resumidamente o teste de Fisher, encontrado

em Priestley(1989), seção 2.5.2.2.

2.5.2.1 Periodograma

Uma das formas de se detectar a existência da sazonalidade é por meio da análise do gráfico do periodograma. Segundo Morettin e Tolo (2006), a análise espectral é fundamental em áreas onde o interesse básico é a procura de periodicidade dos dados. Esta análise é feita no domínio da frequência, portanto, é baseada em modelos não paramétricos.

Priestley (1989) define o periodograma do processo estacionário (a_t) como:

$$I_p(f_i) = \frac{2}{n} \left[\left(\sum_{t=1}^n a_t \cos \frac{2\pi i t}{n} \right)^2 + \left(\sum_{t=1}^n a_t \sin \frac{2\pi i t}{n} \right)^2 \right] \quad (11)$$

onde $0 < f_i < \frac{1}{2}$ e $t = 1, 2, \dots, n$, e $I(f_i)$ indica a intensidade da frequência f_i . A periodicidade pode ser verificada observando-se a existência de picos na frequência $f_i = \frac{i}{n}$, o que indica uma periodicidade de período $\frac{1}{f_i}$.

No gráfico do periodograma, a frequência f_i é representada no eixo das ordenadas e a intensidade da frequência $I(f_i)$ no eixo das abscissas. Geralmente, o pico de maior intensidade é o componente periódico. Caso exista mais de um pico, aplica-se também o teste de Fisher neste período, para verificar se o período é um componente periódico significativo na série.

2.5.2.2 Teste de Fisher

O teste de Fisher é utilizado para confirmar a existência de sazonalidade em uma série temporal. Segundo Priestley (1989), esse teste utiliza os valores do periodograma e detecta grandes periodicidades.

O procedimento para se aplicar o teste é o seguinte:

1. traça-se o periodograma, utilizando um pacote estatístico (R, Statística, Gretl entre outros) ou por meio da frequência padrão dada por (11);
2. toma-se a maior periodicidade encontrada no periodograma, $\max(I_p)$. Calcula-se a estatística:

$$g = \frac{\max I_p}{\sum_{p=1}^{N/2} I_p} \quad (12)$$

3. calcula-se a estatística do Teste de Fisher, z_α , dada por:

$$z_\alpha = \left(\frac{\alpha}{n}\right)^{1/(n-1)} + 1 \quad (13)$$

em que N é o número de observações, $n = \frac{N}{2}$ e α é o nível de significância;

4. testa-se a hipótese de nulidade.

H_0 : não existe periodicidade, isto é, a série não apresenta sazonalidade no período analisado.

Se $g > z_\alpha$, rejeita-se H_0 , isto é, existe sazonalidade no período analisado.

2.5.3 Função de Autocorrelação

Define-se a autocovariância de lag K , γ_k , como a covariância entre Z_t e Z_{t+K} , sendo esta uma medida de dependência entre as duas observações separadas por K intervalos de tempo. Assim,

$$\gamma_k = cov[Z_t, Z_{t+K}] = E[(Z_t - \mu)(Z_{t+K} - \mu)]. \quad (14)$$

Pela expressão (14) tem-se que a autocovariância entre dois pontos quaisquer é a esperança do produto do desvio de cada ponto em relação à média μ do processo.

Para Morettin e Tolo (2006) para um processo estacionário real discreto, de média zero e função de autocovariância (facv), $\gamma_K = E\{Z_t, Z_{t+K}\}$, as seguintes propriedades são válidas:

- $\gamma_0 > 0$
- $\gamma_{-k} = \gamma_k$
- $\gamma_0 \geq |\gamma_k|$
- γ_k é não negativa definida, isto é, $\sum_{j=1}^n \sum_{i=1}^n a_j a_i \gamma_{k_j - k_i} \geq 0$ para quaisquer números reais a_1, \dots, a_n e k_1, \dots, k_n de \mathbb{Z} .

No intuito de se comparar diferentes séries é utilizada uma medida padronizada do coeficiente de autocovariância. Tal medida, a autocorrelação de lag "K", é definida como a razão entre a autocovariância de lag "K" e a autocovariância de lag "0". Desta forma,

$$\rho_K = \frac{\gamma_K}{\gamma_0}. \quad (15)$$

Portanto,

$$\rho_K = \frac{E[(Z_t - \mu)(Z_{t+K} - \mu)]}{\sqrt{E[(Z_t - \mu)^2] E[(Z_{t+K} - \mu)^2]}} = \frac{E[(Z_t - \mu)(Z_{t+K} - \mu)]}{\sigma_z^2} \quad (16)$$

Como na prática os verdadeiros valores das autocorrelações são desconhecidos, pois o que se tem são apenas amostras das observações, as estimativas se fazem necessárias.

Sendo a estimativa da autocovariância, (γ_k) tem-se que

$$\hat{\gamma}_k = c_k = \frac{1}{N} \sum (Z_t - \bar{Z})(Z_{t+k} - \bar{Z}) \quad k = 0, 1, 2, \dots, N - 1. \quad (17)$$

Assim, as estimativas das autocorrelações são dadas por

$$\hat{\rho}_k = r_k = \frac{c_k}{c_0} \quad k = 0, 1, 2, \dots, N - 1. \quad (18)$$

A função de autocorrelação (fac) associa cada valor de k com seu respectivo coeficiente de autocorrelação. A sua representação gráfica é denominada correlograma, sendo obtida dispondo-se em um gráfico os valores de ρ_k em função dos lags k .

Para Morettin e Toloi (2006), a função de autocorrelação possui características especiais de acordo com o tipo de modelo considerado. Para um processo autorregressivo AR(p) decai de acordo com exponenciais e/ou senoides amortecidas, infinitas em extensão. É finita se consideramos um processo de médias móveis MA(q), apresentando um corte após o "lag" q . Se o processo é ARMA(p,q), a fac é infinita em extensão, decaindo de acordo com exponenciais e/ou senoides amortecidas após o lag $q-p$. Mais detalhes sobre estes modelos serão apresentados na próxima seção.

A fac é importante para verificar se a série é estacionária. Ao se construir o correlograma, se o coeficiente de autocorrelação diminuir rapidamente para zero à medida que " k " cresce, a série é estacionária, caso contrário a série temporal é não-estacionária.

O correlograma também é útil para identificar a presença da componente sazonal. Se picos regulares são observados, isto pode indicar a presença de tal componente.

2.5.4 Modelos para séries temporais

De acordo com Morettin e Toloi (2006), os modelos utilizados para descrever séries temporais são modelos de processos estocásticos, isto é, processos controlados por leis probabilísticas.

Ajustar modelos autorregressivos, integrados de médias móveis, ARIMA (p,d,q) a um conjunto de dados é um procedimento baseado em um ciclo iterativo. Esse ciclo consiste em: especificação, identificação, estimação e diagnóstico. Caso o modelo não seja adequado, o ciclo é repetido, voltando-se à fase de identificação (BOX; JENKINS, 1976).

A fase crítica deste ciclo iterativo é a identificação, pois é possível que vários pesquisadores identifiquem modelos diferentes para a mesma série temporal. Algumas vantagens desses modelos são: ser parcimoniosos, isto é, conter um número pequeno de parâmetros; permitir previsões bastante precisas (MORETTIN; TOLOI, 2006).

Para o ajuste do modelo ARIMA(p,d,q) faz-se necessário que a série atenda à condição de estacionariedade, ou seja, que ela se desenvolva aleatoriamente no tempo ao redor de uma média constante. Esta condição pode ser obtida pela tomada de diferenças da série, conforme descrito anteriormente.

Uma notação bastante utilizada nesses modelos é a de operadores, como mostrados a seguir:

1. Operador de translação para o passado, denotado por B e definido por:

$$BZ_t = Z_{t-1}. \quad (19)$$

Generalizando temos:

$$B^m Z_t = Z_{t-m}. \quad (20)$$

2. Operador diferença, denotado por ΔZ_t é definido por:

$$\Delta Z_t = Z_t - Z_{t-1} = (1 - B) Z_t \Rightarrow \Delta = 1 - B. \quad (21)$$

Da equação (2) apresentada temos:

$$\Delta^n Z_t = (1 - B)^n Z_t \Rightarrow \Delta_n = (1 - B)^n \quad (22)$$

2.5.4.1 Modelo autorregressivo e de médias móveis - ARMA

O modelo autorregressivo e de médias móveis de ordem(p,q), ARMA(p,q), é a combinação dos processos autorregressivos de ordem p, AR(p), e de médias móveis de ordem q, MA(q).

Se q=0, tem-se o modelo ARMA(p,0), isto é, autorregressivo de ordem p, AR(p). Esse modelo pode ser escrito como uma soma ponderada finita de valores passados de Z_t mais um ruído branco a_t , ou seja,

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t = \sum_{j=1}^p \phi_j Z_{t-j} + a_t. \quad (23)$$

Isolando a_t tem-se:

$$\begin{aligned} a_t &= Z_t - \phi_1 Z_{t-1} - \dots - \phi_p Z_{t-p} \\ &= Z_t - \phi_1 B Z_t - \dots - \phi_p B^p Z_t \\ &= (1 - \phi_1 B - \dots - \phi_p B^p) Z_t \end{aligned} \quad (24)$$

em que $\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$ é o polinômio autorregressivo de ordem p. Portanto,

$$\phi(B) Z_t = a_t \quad (25)$$

ou

$$Z_t = \phi^{-1}(B)a_t. \quad (26)$$

Como $\phi(B)$ é finito, o processo $AR(p)$ é invertível para qualquer p e será estacionário se as raízes do polinômio, $\phi(B) = 0$, estiverem fora do círculo unitário.

Se $p = 0$ tem-se o modelo $ARMA(0,q)$, isto é, de médias móveis de ordem q , $MA(q)$. Este modelo pode ser escrito como uma soma ponderada finita de ruídos branco do presente e do passado, ou seja,

$$Z_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (27)$$

com $\theta_0 = 1$. Utilizando (19) e (20) pode-se escrever (27) da seguinte forma:

$$\begin{aligned} Z_t &= a_t - \theta_1 B a_t - \dots - \theta_q B^q a_t \\ &= (1 - \theta_1 B - \dots - \theta_q B^q) a_t \end{aligned} \quad (28)$$

em que $\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ é o polinômio de médias móveis de ordem q . Portanto,

$$Z_t = \theta(B)a_t. \quad (29)$$

Como $\theta(B)$ é finito, o processo $MA(q)$ é estacionário para qualquer q e será invertível se as raízes do polinômio, $\theta(B) = 0$, estiverem fora do círculo unitário.

Se $p \neq 0$ e $q \neq 0$, o modelo $ARMA(p,q)$ pode ser escrito como

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (30)$$

ou

$$\phi(B)Z_t = \theta(B)a_t \quad (31)$$

em que $\phi(B)$ e $\theta(B)$ são os operadores autorregressivos e de médias móveis, respectivamente.

As condições de estacionariedade e invertibilidade são, respectivamente, que as raízes dos polinômios, $\phi(B) = 0$ e $\theta(B) = 0$, estejam fora do círculo unitário.

2.5.4.2 Modelos ARIMA

Segundo Morettin e Toloí (2006), muitas séries encontradas na prática são não estacionárias, ou seja, não se desenvolvem em torno de uma média constante como, por exemplo, séries econômicas e financeiras que apresentam, em geral, tendências. Pode-se também ter uma forma de não-estacionariedade explosiva, como no crescimento de uma colônia de bactérias.

Quando uma série não apresenta a componente sazonal, mas apresenta a componente tendência, ou estes componentes são não-estacionários homogêneos, ela pode ser representada pelo modelo ARIMA.

Box, Jenkins e Reinsel (1994) consideram o modelo como

$$\varphi(B)Z_t = \theta(B)a_t \quad (32)$$

em que $\varphi(B)$ é um operador autorregressivo não-estacionário de ordem, $p + d$, com d raízes sobre o círculo unitário e p raízes fora, ou seja,

$$\varphi(B)Z_t = \phi(B)\Delta^d Z_t = \phi(B)(1 - B)^d Z_t \quad (33)$$

logo

$$\phi(B)\Delta^d Z_t = \theta(B)a_t \quad (34)$$

em que $\Delta^d Z_t$ é estacionária. Tomando

$$W_t = \Delta^d Z_t \quad (35)$$

e substituindo em (34) tem-se:

$$\phi(B)W_t = \theta(B)a_t. \quad (36)$$

Portanto, o modelo (34) pode ser representado por um modelo ARMA(p,q). Uma alternativa para escrever (35) é

$$Z_t = \frac{W_t}{\Delta^d} = W_t \Delta^{-d}. \quad (37)$$

A equação (37) implica que o processo estacionário (34) pode ser obtido por uma soma (integral), daí o modelo autorregressivo, integrado, de médias móveis.

2.5.4.3 Modelos ARIMA sazonal - SARIMA

Quando uma série temporal apresenta um componente periódico, com um período máximo de 12 meses (sazonalidade), é necessário acrescentar uma componente sazonal ao modelo. Podem-se ter dois tipos de modelos sazonais: determinísticos e estocásticos.

De acordo com Morettin e Toloi (2006), uma série sazonal é estocástica quando apresenta correlações significativas nos *lags* sazonais, isto é, múltiplos de períodos, e é determinística quando torna-se estacionária após tomar D diferenças da série. Muitas vezes, a série pode apresentar essas duas características.

Box e Jenkins (1976) propõem o modelo sazonal multiplicativo, denotado por $SARIMA(p, d, q) \times (P, D, Q)_s$, representado por

$$\phi(B)\Phi(B^s)\Delta^d\Delta_s^D Z_t = \theta(B)\Theta(B^s)a_t \quad (38)$$

em que

- $\phi(B) = 1 - \phi_1 B^1 - \dots - \phi_p B^p$ é o polinômio autorregressivo de ordem p ;
- $\Phi(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_P B^{Ps}$ é o polinômio autorregressivo sazonal de ordem P ;
- $\Delta^d = (1 - B)^d$ é o operador diferença e d é o número de diferenças necessárias para retirar a tendência da série;
- $\Delta_s^D = (1 - B^s)^D$ é o operador diferença generalizado, quando duas observações estão distantes entre si de s intervalos de tempos que apresentam alguma semelhança, e D é o número de diferenças de *lags* s necessárias para retirar a sazonalidade da série.
- $\theta(B) = 1 - \theta_1 B^1 - \dots - \theta_q B^q$ é o polinômio de médias móveis de ordem q ;
- $\Theta(B^s) = 1 - \Theta_s B^s - \dots - \Theta_Q B^{Qs}$ é o polinômio de médias móveis sazonal de ordem Q .

Quando a série possui apenas sazonalidade estocástica ajusta-se o modelo SARIMA com $D = 0$, e se possui apenas sazonalidade determinística ajusta-se o modelo SARIMA, com $P = Q = 0$

2.5.5 Critério para escolha de modelo

Vários modelos podem ser identificados para descrever uma série e existem critérios para escolha do melhor modelo. A seguir serão apresentados alguns

desses critérios.

2.5.5.1 Critério de Akaike

Akaike (1973) sugere escolher como melhor modelo aquele cujas ordens p e q minimizam o critério de Akaike (AIC) normalizado.

Na comparação de diversos modelos, com N fixo, este critério pode ser expresso por:

$$AIC = N \log(\hat{\sigma}_\alpha^2) + 2(k + l + 1) \quad (39)$$

em que $\hat{\sigma}_\alpha^2$ é o estimador de máxima verossimilhança de σ_α^2 , $0 \leq k \leq p$ e $0 \leq l \leq q$.

Entre os vários modelos propostos, será escolhido como o melhor modelo aquele que tiver o menor valor de AIC.

2.5.5.2 Mean Absolute Percentage Error - MAPE

De acordo com Morettin e Tolo (2006), uma das medidas utilizadas para analisar os erros gerados pelas previsões encontradas é o MAPE, que é dado por:

$$MAPE = \frac{1}{n} \cdot \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100 \quad (40)$$

onde A_t é o valor real e F_t é o valor previsto. O modelo que deverá ser escolhido será aquele que apresentar menor valor de MAPE.

2.5.6 Teste para resíduo

Um teste utilizado para verificar se o resíduo é independente, identicamente distribuído (i.i.d), isto é, se o resíduo é um ruído branco, foi sugerido por

Box e Pierce (1970). Este teste é baseado nas k primeiras estimativas das autocorrelações, \hat{r}_k , dos resíduos, sendo denominado Teste de Box-Pierce. Caso o modelo ajustado seja apropriado, a estatística do teste, com distribuição aproximadamente qui-quadrado (χ^2), será

$$Q(k) = n(n+2) \sum_{j=1}^k \frac{\hat{r}_j^2}{(n-j)}. \quad (41)$$

A hipótese de ruído branco será aceita se ($Q < \chi^2$), com $(k-p-q)$ graus de liberdade, sendo k o número de *lags*, p a ordem da parte autorregressiva do modelo e q a ordem da parte de médias móveis. Segundo Morettin e Toloí (1986), a construção do correlograma e do seu intervalo de confiança (IC) é o suficiente para verificar se uma série é ruído branco. Dentre o total das correlações, 95% destas deverão estar dentro desde IC. No modelo SARIMA consideram-se os coeficientes sazonais nos graus de liberdade da distribuição qui-quadrado, tendo, então, $(k-p-q-P-Q)$ graus de liberdade. Neste estudo serão tomadas as primeiras 24 \hat{r}_k .

2.6 Modelos de regressão linear

2.6.1 Modelos de regressão linear simples

A análise de regressão é uma técnica estatística para investigar e modelar a relação entre variáveis, sendo uma das mais utilizadas na análise de dados. O objetivo do modelo da análise de regressão é estimar os parâmetros desconhecidos do modelo. Existem várias técnicas de estimação desses parâmetros, como o método dos mínimos quadrados, o método bayesiano e o método bootstrap.

Segundo Charnet et. al (1999), seja Y uma variável aleatória de interesse, muitas vezes denominada variável resposta, e seja X uma variável aleatória que

denominaremos auxiliar ou regressora. O modelo de regressão linear simples descreve a variável Y como uma soma de uma quantidade determinística e uma quantidade aleatória. A parte determinística, uma reta em função de X , representa a informação sobre Y que já poderíamos "esperar", apenas com o conhecimento da variável X . A parte aleatória, denominada erro, representa os inúmeros fatores que, conjuntamente, podem interferir em Y .

Utilizando β_0 e β_1 para denotar os coeficientes da reta, ϵ a variável erro, σ^2 a variância da variável erro, e x um valor específico da variável X , podemos sumarizar o modelo de regressão linear simples de acordo com a equação 42

$$Y = \beta_0 + \beta_1 x + \epsilon \quad (42)$$

frequentemente supõem-se que o modelo de probabilidade do erro é o modelo normal, em que β_0, β_1 são constantes, $\epsilon \sim N(0; \sigma^2)$.

2.6.2 Modelos de regressão linear múltipla

O modelo de regressão linear múltipla também descreve Y como uma soma de parte determinística e parte aleatória, sendo a parte determinística mais geral, de forma que se pode expressar o valor esperado de Y de duas maneiras, ou seja: como função de várias variáveis regressoras, ou como função de polinômio de maior grau de uma única variável regressora (CHARNET et. al. 1999).

Tem-se o interesse em avaliar a relação de uma variável de interesse Y (variável dependente ou variável resposta) em relação a k variáveis X_j (variável independente ou covariável), $j = 1, 2, \dots, k$. Portanto, esse modelo pode ser dado pela equação 43:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \epsilon_i \quad i = 1, 2, \dots, n \quad (43)$$

em que, n é o número de indivíduos, y_i é a observação da variável dependente para o i -ésimo indivíduo, $X_i = (x_{i1}, x_{i2}, \dots, x_{ik})$ é um vetor de observações das variáveis independentes para o i -ésimo indivíduo, $\beta = (\beta_0, \beta_1, \beta_2, \dots, \beta_k)$ é um vetor de coeficientes de regressão (parâmetros) e ϵ_i é um componente de erro aleatório. Assume-se que esses erros são independentes e seguem distribuição normal com média zero e variância desconhecida σ^2 . Então o modelo (43) é chamado de regressão linear múltipla, pois envolve mais de um coeficiente de regressão. O adjetivo *linear* indica que o modelo é linear em relação aos parâmetros $\beta = (\beta_0, \beta_1, \beta_2, \dots, \beta_k)$, e não porque y é uma função linear dos x 's.

2.6.2.1 O método de quadrados mínimos

O método de quadrados mínimos analisa as n diferenças entre cada valor y e o valor na reta, correspondentes ao respectivo valor x . A reta selecionada é a reta que apresenta a menor soma de quadrados de tais diferenças (CHARNET et. al. 1999).

Pode-se equacionar o problema da escolha de uma reta que se ajuste ao conjunto de n pontos, $(x_1, y_1), \dots, (x_n, y_n)$ pelo critério de quadrados mínimos da seguinte forma.

Seja $y = a + bx$ a representação de uma reta genérica, onde a e b são valores reais. Então, trata-se de encontrar o mínimo da seguinte função, em que a e b , onde $a \in \mathfrak{R}$ e $b \in \mathfrak{R}$:

$$\sum_{i=1}^n [y_i - (a + bx_i)]^2. \quad (44)$$

Para encontrar esse mínimo precisamos obter as seguintes derivadas parciais:

$$\frac{\partial}{\partial a} \sum_{i=1}^n [y_i - (a + bx_i)]^2 \quad (45)$$

e

$$\frac{\partial}{\partial b} \sum_{i=1}^n [y_i - (a + bx_i)]^2 \quad (46)$$

Portanto tem-se,

$$y = \hat{a} + \hat{b}x \hat{a} = \frac{1}{n} \sum_{i=1}^n y_i - \hat{b} \frac{1}{n} \sum_{i=1}^n x_i \hat{b} = \frac{\sum_{i=1}^n x_i y_i - \frac{1}{n} \sum_{i=1}^n y_i \sum_{i=1}^n x_i}{\sum_{i=1}^n x_i^2 - \frac{1}{n} (\sum_{i=1}^n x_i)^2} \quad (47)$$

Esta solução corresponde a um mínimo, pela simples constatação de que não existe um máximo para esta função. É só notar que, para qualquer reta que passe totalmente acima (ou abaixo) dos pontos, sempre pode-se apontar outra reta cuja soma dos quadrados das diferenças é ainda maior. Logo, o ponto extremo é o ponto de mínimo (CHARNET et. al. 1999).

2.6.2.2 Coeficiente de determinação - R^2

Temos a seguinte relação:

$$SQT = SQE + SQR_{eg} \quad (48)$$

A soma de quadrados total de Y, (SQT) mede a variabilidade dos valores observados em torno de sua média, enquanto a soma de quadrados dos resíduos, (SQE), nos dá uma medida do ajuste do modelo considerado - quanto menos a SQE melhor o ajuste do modelo aos valores observados.

Para uma melhor compreensão de como a SQE nos informa sobre o ajuste

do modelo, suponha a situação fictícia em que os valores de Y , calculados pela reta estimada, coincidem com os seus respectivos valores observados (ou seja, os valores observados de Y já estão em linha reta, em função de X).

A situação fictícia acima nos leva ao seguinte raciocínio - em uma situação real, quando a SQE não é igual a zero, sempre teremos a SQR_{eg} menor do que a SQT . No entanto, quanto mais próximo estiverem SQR_{eg} e SQT , menor será a SQE e, conseqüentemente, melhor será o ajuste do modelo considerado. Desta forma, quanto mais próximo de 1 estiver o quociente SQR_{eg}/SQT melhor será o ajuste do modelo. Portanto, esse quociente nos fornece uma medida do ajuste.

$$R^2 = \frac{SQR_{eg}}{SQT} \quad (49)$$

O coeficiente de determinação, R^2 , é interpretado como a proporção da variabilidade dos Y 's observados, explicada pelo modelo considerado. O valor de R^2 pertence ao intervalo $[0;1]$ e, quanto mais próximo de 1, melhor o ajuste do modelo considerado. É importante notarmos que R^2 está diretamente ligado ao modelo que estamos considerando e não somente aos dados, de forma que para um mesmo conjunto de dados, se ajustarmos modelos diferentes, teremos distintos valores de R^2 para cada modelo. Assim, em situações especiais, podem-se comparar modelos através de seus coeficientes de determinação.

A inclusão de inúmeras variáveis, mesmo que tenham muito pouco poder explicativo sobre a variável resposta, aumentarão o valor de R^2 , o que é ruim pois incentiva a inclusão indiscriminada de variáveis, indo contra o princípio da parcimônia. Para resolver esse "problema", podem-se usar uma medida ajustada do coeficiente de determinação que é penalizada quando incluímos variáveis pouco explicativas. Esse é o R^2 ajustado

$$R_a^2 = 1 - \frac{n-1}{n-(k+1)}(1-R^2) \quad (50)$$

onde $(k+1)$ representa o número de variáveis explicativas mais a constante. Note que a inclusão de mais variáveis com pouco poder explicativo prejudica o valor do R^2 ajustado porque aumenta k em uma unidade e não traz muito incremento em R^2 .

2.6.2.3 Seleção de variáveis regressoras

Existem vários procedimentos e critérios utilizados para a seleção de um subconjunto de variáveis regressoras para serem incorporadas no modelo. No entanto, nem sempre métodos diferentes chegam ao mesmo resultado, porque podem-se ter modelos de ajustes equivalentes. Dentre esses procedimentos apresentam-se os seguintes:

- todas as regressões possíveis;
- método "passo a frente"(forward);
- método "passo atrás"(backward);
- método "passo a passo"(stepwise).

2.6.2.4 Método Backward (passo atrás)

Este procedimento caracteriza-se por incorporar, inicialmente, todas as variáveis auxiliares em um modelo de regressão linear múltipla e percorrer etapas, nas quais uma variável por vez pode vir a ser eliminada. Se em uma dada etapa não houver eliminação de alguma variável, o processo é então interrompido e as variáveis restantes definem o modelo final.

Numa dada etapa, temo-se um determinado modelo que denominaremos modelo completo da etapa e são investigadas as contribuições individuais das variáveis a esse modelo. A variável de pior desempenho é eliminada, a não ser que esta atenda a um critério mínimo exigido. No julgamento de uma variável comparamos o modelo completo com o modelo reduzido, pela retirada de tal variável. Observamos a soma de quadrados de regressão extra, assim como a estatística do teste de sua contribuição, dada por:

$$\frac{SQR_{eg}^c - SQR_{eg}^r}{\hat{\sigma}^2} \quad (51)$$

sendo SQR_{eg}^c e $\hat{\sigma}^2$ calculadas sob o modelo completo e SQR_{eg}^r calculada sob o modelo reduzido. A estatística (51) testa a contribuição da variável após a inclusão das demais. A contribuição é significativa se o valor da estatística for maior que um quantil especificado da distribuição F com 1 e $(n - m - 1)$ graus de liberdade, sendo m o número de variáveis no modelo completo. Assim, se o valor da estatística for menor que esse quantil especificado da distribuição F, a contribuição não é considerada significativa e o modelo reduzido deverá ser preferido. Se observamos várias variáveis não significantes, apenas uma variável é eliminada em uma etapa - aquela cuja estatística do teste tiver o menor valor. Quando uma variável é eliminada, passamos para a nova etapa cujo modelo completo não contém a variável que foi descartada. Se todas as variáveis são significantes o processo é concluído, e o modelo completo desta etapa é o modelo final. Serão sumarizados a seguir os passos de uma etapa deste procedimento.

2.6.2.5 Análise de resíduos

Os resíduos de um modelo de regressão linear têm uma relação muito forte com a qualidade do ajuste feito. Assim, a análise dos resíduos tem uma importân-

cia fundamental na verificação da qualidade dos ajustes de modelos. Basicamente, essa análise fornece evidências sobre possíveis violações nas suposições do modelo, tais como a de normalidade, independência e, quando for o caso, ainda fornece indícios de falta de ajuste do modelo proposto (CHARNET et. al. 1999).

Para verificar a suposição de normalidade dos dados é utilizado o gráfico dos escores normais. Esse gráfico é construído da seguinte forma:

- geram-se m amostras aleatórias de tamanho prefixado, n , de uma distribuição normal padrão;
- ordena-se cada uma dessas m amostras, obtendo-se as estatísticas de ordem, como se segue:

$$\begin{aligned}
 & - X_1^1 \leq X_2^1 \leq \dots X_n^1 \text{ amostra 1 ordenada} \\
 & X_1^2 \leq X_2^2 \leq \dots X_n^2 \text{ amostra 2 ordenada} \\
 & \vdots \\
 & X_1^m \leq X_2^m \leq \dots X_n^m \text{ amostra } m \text{ ordenada}
 \end{aligned}$$

- usando-se as m amostras, calculam-se as médias de cada um dos n valores ordenados:

$$\bar{X}_{(i)} = \frac{\sum_{j=1}^m X_{(i)}^j}{m} \quad i = 1, \dots, n. \quad (52)$$

As médias obtidas acima são denominadas escores normais. Construindo um gráfico dos resíduos padronizados ordenados *versus* os escores normais, pode-se detectar alguma evidência contra a suposição de normalidade. Quanto mais próximos de uma reta estiverem os pontos maior a concordância de normalidade dos dados.

A estatística Durbin-Watson é um teste estatístico usado para detectar a

presença de autocorrelação (a relação entre valores separados entre si por um intervalo de tempo determinado) nos resíduos a partir de uma análise de regressão. A estatística é definida como:

$$d = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2} \quad (53)$$

onde T é o número de observações. Uma vez que d é aproximadamente igual a $2(1 - r)$, onde r é a autocorrelação da amostra dos resíduos, $d = 2$ indica que não há autocorrelação. O valor de d sempre se situa entre 0 e 4. Se a estatística Durbin-Watson é substancialmente menor que 2, existe evidência de correlação serial positiva. Como regra básica, se Durbin-Watson é inferior a 1.0 pode haver motivo para alarme. Pequenos valores de d indicam termos de erro sucessivas são, em média, perto do valor uns aos outros, ou positivamente correlacionados. Se $d > 2$ termos de erro sucessivo e são, em média, muito diferente em termos de valor uns aos outros, isto é, negativamente correlacionados. Em regressão, isto pode implicar uma subestimação do nível de significância estatística.

3 MATERIAL E MÉTODOS

As séries a serem consideradas para análise são séries históricas das cidades de Lavras, em Minas Gerais, e Cuiabá, em Mato Grosso. A escolha dessas cidades se deu pelo fato da facilidade da obtenção dos dados e por serem de regiões e climas diferentes. A Figura 7 mostra a localização no mapa do Brasil das duas cidades em estudo.



Figura 7 Localização da cidade de Lavras (Minas Gerais) e Cuiabá (Mato Grosso)

O município de Lavras situa-se na Zona fisiográfica Sul do Estado de Minas Gerais, região do Campo das Vertentes, fazendo parte da Microrregião Alto Rio Grande, que é constituída por 9 municípios: Lavras, Ribeirão Vermelho, Ijaci, Carrancas, Itutinga, Nepomuceno, Itumirim, Luminárias e Ingaí.

Possui apenas o distrito sede com área de $564,5 \text{ Km}^2$, abrangendo cerca de 5,59% da superfície total da microrregião. A área do perímetro urbano corresponde aproximadamente a $117,84 \text{ Km}^2$ e a área urbanizada corresponde a $14,16$

Km².

Sua posição geográfica é determinada pelo paralelo, 21° 14' 30" de latitude sul e 45° 00' 10" de longitude oeste de Greenwich. A sede do município encontra-se a 919 metros de altitude.

O clima de Lavras é classificado como mesotérmico (KÖPEN), apresentando verões brandos e chuvosos. As temperaturas médias anuais situam-se em torno de 19,3°C, com máximas de 27,8°C e mínimas de 13,5°C. A precipitação média é de 1.411 mm, estando 65 a 70% desse total concentrados nos meses de dezembro a março. Nos meses mais frios (junho e julho), o volume de chuva é muito reduzido, chegando a ser nulo, em alguns anos.

Nas estimativas realizadas para 2010 pelo IBGE ², a população de Lavras é de 92.171 habitantes.

Município polo da região Sul de Minas, Lavras se destaca pelo Turismo, pela Cultura e pela produção agropecuária, representada pelo café e por um dos melhores rebanhos de gado leiteiro do Estado.

Lavras está ligada a grandes capitais por duas rodovias principais: pela BR 381, Fernão Dias, conectando-a a Belo Horizonte, a 230 quilômetros, e a São Paulo, a 370 quilômetros, e pela BR 265 chega-se a BR 040 que dá acesso ao Rio de Janeiro, a 420 quilômetros.

Cuiabá é um município brasileiro pertencente à região centro-oeste, capital do estado do Mato Grosso. Situa-se no centro geodésico da América do Sul, localizada nas coordenadas geográficas, 15° 35' 56" latitude Sul e 56° 06' 01" longitude Oeste e a uma altitude de 151 metros acima do nível do mar.

O município é cercado por três grandes ecossistemas: a Amazônia, o cerrado e o pantanal. A vegetação predominante no município é o cerrado. Está

²Instituto Brasileiro de Geografia e Estatística, <http://www.ibge.gov.br/home/>

situado na margem esquerda do rio de mesmo nome e forma uma conurbação ³ com o município de Várzea Grande.

Segundo a estimativa realizada para 2010 pelo IBGE, a população de Cuiabá é de 551.350 habitantes.

Fundada em 1719, ficou praticamente estagnada desde o fim das jazidas de ouro até o início do século XX. Desde então, apresentou um crescimento populacional acima da média nacional, atingindo seu auge nas décadas de 1970 e 1980. Nos últimos 15 anos, o crescimento diminuiu, acompanhando a queda que ocorreu na maior parte do país. Hoje, além das funções político-administrativas, é o polo industrial, comercial e de serviços do estado. É conhecida como "cidade verde", por causa da grande arborização.

Cuiabá é famosa pelo seu forte calor, apesar de a temperatura no inverno poder chegar esporadicamente aos $10^{\circ}C$, fato atípico, causado pelas frentes frias que vêm do sul, e que podem durar apenas um ou dois dias consecutivos, para logo em seguida voltar ao calor habitual.

A temperatura média em Cuiabá gira em torno de $24^{\circ}C$. O clima é tropical e úmido. As chuvas se concentram de setembro a maio, enquanto que no resto do ano as massas de ar seco sobre o centro do Brasil inibem as formações chuvosas. A precipitação média anual é de 1469,4 mm, com intensidade máxima em janeiro, fevereiro e março.

A temperatura máxima média chega aos $35^{\circ}C$, mas as máximas absolutas podem chegar aos $40^{\circ}C$ nos meses mais quentes e abafados; em dias chuvosos, a temperatura máxima não passa de $28^{\circ}C$. A mínima média em julho, o mês mais frio, é de $16^{\circ}C$ com sensação térmica de $11^{\circ}C$.

³É um fenômeno urbano que ocorre quando duas ou mais cidades se desenvolvem uma ao lado da outra, de tal forma que acabam se unindo como se fosse apenas uma.

Segundo dados do INMET 2011 ⁴ a cidade possui pequena amplitude térmica, exceto em fenômenos de friagem, temperatura média anual de $26.8^{\circ}C$, com média das máximas de $42^{\circ}C$ e médias das mínimas de $15^{\circ}C$ e insolação total média de 2.179 horas. A direção predominante dos ventos é Norte e Noroeste durante boa parte do ano e Sul no período de inverno.

Na classificação de KÖPEN pode-se observar que o clima de Cuiabá é do tipo Aw, isto é, tropical semiúmido, com 4 a 5 meses secos e duas estações bem definidas, uma seca (outono e inverno) e uma chuvosa (primavera e verão), com características de continentalidade.

Foram considerados o número de casos notificados de dengue, séries climáticas como temperatura mínima, temperatura máxima, temperatura média, umidade relativa do ar e índice pluviométrico da cidade de Lavras, Minas Gerais.

As séries de casos de dengue da cidade de Lavras foram fornecidas pela Secretaria de Saúde, setor de epidemiologia, da Prefeitura Municipal de Lavras. Os dados climáticos foram cedidos pelo setor de climatologia do Departamento de Engenharia da Universidade Federal de Lavras (UFLA). Foram dados mensais no período de janeiro de 2001 a junho de 2010.

Para Cuiabá consideramos as séries do número de casos notificados de dengue na cidade e séries climáticas como temperatura mínima, temperatura máxima e índice pluviométrico.

O número de casos de dengue da cidade de Cuiabá foram fornecidos pela Secretaria de Saúde, setor de epidemiologia, da Prefeitura Municipal de Cuiabá. Os dados climáticos foram cedidos pelo Instituto Nacional de Meteorologia (INMET).

Os dados são mensais do período de janeiro de 2001 a dezembro 2010. Os

⁴Instituto Nacional de Meteorologia <http://www.inmet.gov.br/>

casos de dengue foram dados mensais de janeiro de 2001 a setembro de 2010.

A metodologia utilizada para o ajuste dos modelos de cada série em estudo correspondem a:

1. análise do gráfico da série original e do gráfico da amplitude em função da média, verificando se existe necessidade de transformação dos dados;
2. análise das séries e sua função de autocorrelação, verificando os indícios da existência de tendência e sazonalidade;
3. verificação de existência das componentes de tendência e sazonalidade através da aplicação do teste de sinal e do teste de Fisher, respectivamente;
4. realização do número de diferenças necessárias para retirar a tendência e a sazonalidade determinística das séries;
5. análise das funções de autocorrelação (fac) e autocorrelação parcial (fapc) das séries diferenciadas (livre de tendência e/ou sazonalidade determinística).
6. ajuste do modelo e verificação das estimativas significativas;
7. teste a partir da fac dos resíduos do modelo ajustado para verificar se o resíduo é ruído branco;
8. para o caso de mais de um modelo ajustado para a série, aplica-se o critério de Akaike e do EQMP para escolha do melhor modelo que se ajusta aos dados;
9. identificação do modelo matemático com os parâmetros estimados;

10. ajuste do modelo de regressão, com os resíduos das séries ajustadas, onde a variável dependente é o resíduo do modelo de casos de dengue e os resíduos dos modelos de séries climáticas são as variáveis independentes.

Para as análises estatísticas dos dados foi utilizado o programa Gretl 1.9.2. Gretl (acrônimo de Gnu Regression, Econometrics and Time-series Library) é um software livre que compila e interpreta dados econométricos. O programa é escrito na linguagem C e usa o Gnuplot para gerar gráficos. Pode ser utilizado em conjunto com o programa R. Inclui a possibilidade de produzir arquivos \LaTeX dos modelos estimados. O site para download do Gretl é *http://gretl.sourceforge.net/win32/index_pt.html*. Este software possibilita fazer a análise completa de uma série temporal, desde análise gráfica até previsões dos dados.

4 RESULTADOS

Neste capítulo são apresentados os resultados deste trabalho, em duas etapas. Na primeira parte são mostrados os modelos obtidos para a cidade de Cuiabá (Mato Grosso) e a segunda parte os modelos encontrados para a cidade de Lavras (Minas Gerais).

4.1 Análise das séries temporais climáticas e casos de dengue da cidade de Cuiabá - Mato Grosso

4.1.1 Casos de dengue

A Figura 8 apresenta o gráfico da série de casos de dengue da cidade de Cuiabá, e a Figura 9 mostra as funções de autocorrelação (ACF) e autocorrelação parcial (PACF) para a série de casos de dengue da cidade de Cuiabá.




Figura 8 Representação gráfica da série mensal do número de casos de dengue da cidade de Cuiabá, do período de janeiro de 2001 a dezembro de 2009

Primeiramente foi feita a análise do comportamento da média com relação

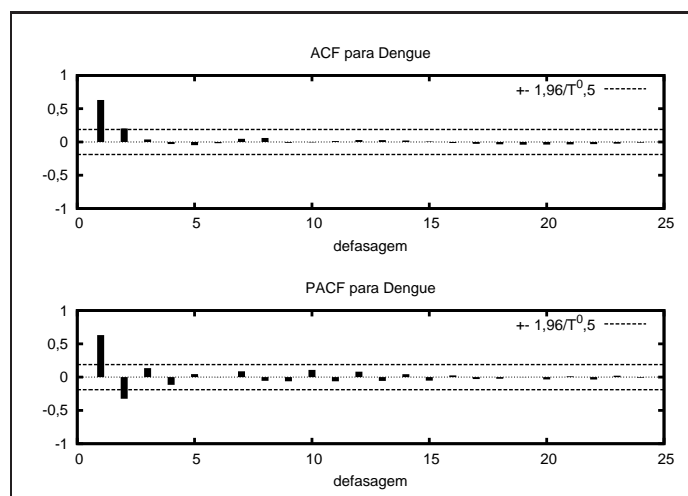


Figura 9 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série do número de casos de dengue da cidade de Cuiabá

à amplitude dos dados para verificar a necessidade de estabilizar a variância. A série foi dividida em grupos de 12 observações, e foi feito o cálculo da média e amplitude dos dados para cada grupo de observações. A Figura 10 mostra que a amplitude é diretamente proporcional à média, o que torna necessário a transformação logarítmica em toda a série temporal em estudo. A série original apresentava valores zeros, então foi somado 0.1 para todos os valores.

A Figura 11 mostra a série de dengue logaritmizada, e os gráficos das funções de autocorrelação e autocorrelação parcial podem ser vistos na Figura 12.

Visualmente faz-se a suposição da presença da componente sazonalidade e a não ocorrência da componente tendência. Deve-se aplicar o teste de Fisher, descrito na seção (2.5.2.2), para sazonalidade, e a ausência da tendência pode ser percebida pela função de autocorrelação.

Para isso foi construído um periodograma para verificação da existência de sazonalidade no conjunto de dados. O periodograma da série transformada de casos de dengue está apresentado na Figura 13.

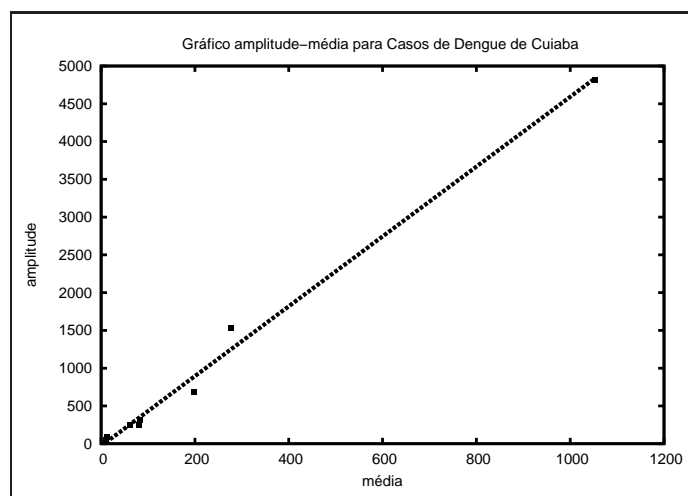


Figura 10 Gráfico da média x amplitude dos dados da série de casos de dengue da cidade de Cuiabá de 2001 a 2009




Figura 11 Série mensal do ln dos casos de dengue da cidade de Cuiabá, do período de janeiro de 2001 a dezembro de 2009

Pode-se inferir que existe um pico no período igual a 12. Testando então a existência sazonal no período 12, aplicou-se o teste proposto por Fisher e obteve-se:

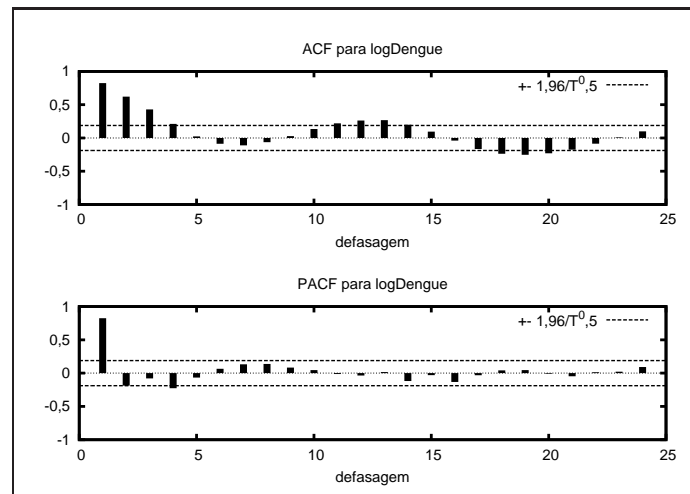


Figura 12 Representação das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) do ln da série mensal do número de casos de dengue da cidade de Cuiabá

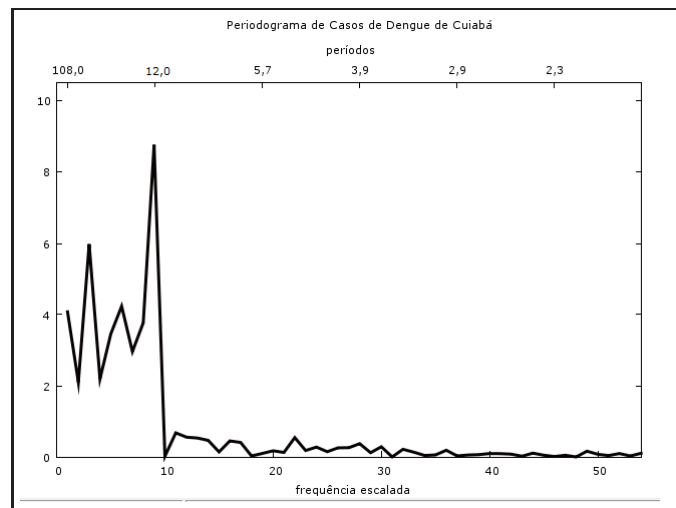


Figura 13 Periodograma de casos de dengue de Cuiabá, do período de janeiro de 2001 a dezembro de 2009

$$n = \frac{N}{2} = \frac{108}{2} = 54 \quad \alpha = 0,05$$

$$z_{0,05} = 1 - \left(\frac{0,05}{54} \right)^{\frac{1}{54-1}} = 0,12 \quad g = \frac{8,77}{45,7} = 0,19$$

Como $g > z$, rejeita-se H_0 ao nível de significância $\alpha = 0,05$, isto é, a série transformada apresenta sazonalidade no período analisado.

Mediante as análises preliminares realizadas, confirmou-se que a série não possui tendência e apresenta sazonalidade. Logo, torna-se necessário realizar diferença na série, a fim de torná-la estacionária. Foi aplicada uma diferença na série, de $lag = 12$ para remoção de sazonalidade. (Figura 14)




Figura 14 Série estacionária casos de dengue de Cuiabá

Após esses ajustes, e baseado na metodologia de Box e Jenkins, a identificação do modelo que se ajusta aos dados é realizada através das *fac* e *facp* da série estacionária (Figura 15). A *fac* apresenta correlação nos seis primeiros "lags" e a *facp* correlação na "lag" 1.

Sendo assim, para a série em questão, foi proposto o seguinte modelo $SARIMA(1, 0, 0) \times (1, 1, 0)_{12}$ de acordo com a equação 54.

$$(1 - \phi_1 B)(1 - \Phi_1 B^{12})(1 - B^{12})Z_t = a_t \quad (54)$$

Na Tabela 1 são apresentadas as estimativas dos parâmetros do modelo 54.

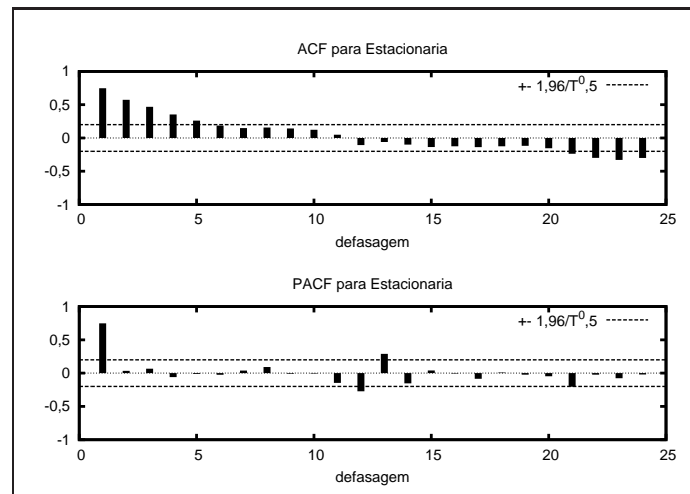


Figura 15 Função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série estacionária casos de dengue de Cuiabá

Tabela 1 Estimativas dos parâmetros do modelo $SARIMA(1,0,0) \times (1,1,0)_{12}$ e seus respectivos erros padrão e p-valor e o valor de Akaike para série do número de casos de dengue da cidade de Cuiabá - MT

SARIMA(1,0,0)x(1,1,0) ₁₂			
Parâmetro	Coefficiente	Erro Padrão	p-valor
ϕ_1	0,8819	0,0551	1,77e-057 ***
Φ_1	-0,5319	0,0949	2,09e-08 ***

Critério de Akaike 333,5416

Significância ***0,01

As análises das funções de autocorrelação e autocorrelação parcial do resíduo do modelo $SARIMA(1,0,0) \times (1,1,0)_{12}$, conforme Figura 16, não mostram correlação significativa. Com isso, pode-se afirmar que esse modelo ajusta-se aos dados e que o resíduo a_t é ruído branco.

A aplicação do teste de Box-Pierce, visto na seção (2.5.6), forneceu os seguintes resultados:

$$SARIMA(1,0,1)(1,1,0)_{12} \rightarrow Q_{24} = 19,70 < \chi_{18,0.05}^2 = 28,86 \quad (55)$$

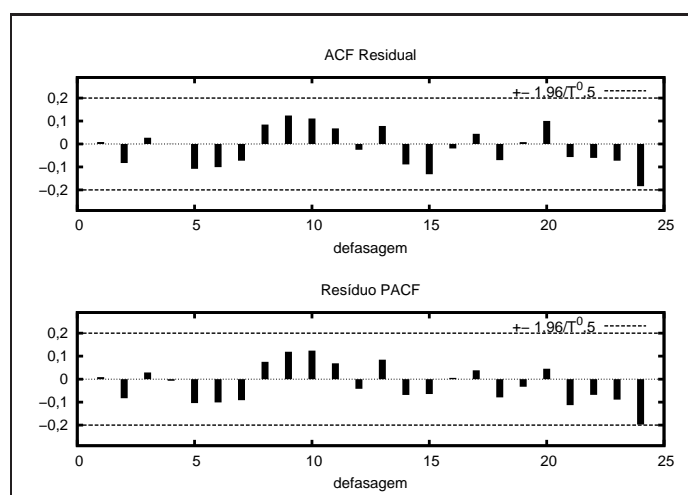


Figura 16 Função de autocorrelação (ACF) e autocorrelação parcial (PACF) do resíduo do modelo ajustado para a série Ln de casos de dengue de Cuiabá

De acordo com 55, confirmou-se que a_t é um ruído branco.

4.1.2 Séries climáticas de Cuiabá

Para cada série climática da cidade de Cuiabá, utilizou-se os mesmos critérios estabelecidos no estudo da série de casos de dengue, visto na seção anterior. A Figura 28 mostra as séries climáticas utilizadas nesse estudo.

E a Tabela 2 apresenta os modelos SARIMA ajustados para cada série climática da cidade de Cuiabá.

Tabela 2 Modelos encontrados para as séries climática da cidade de Cuiabá-MT

Série temporal	Modelos SARIMA
Temperatura máxima	$SARIMA(1, 0, 0) \times (0, 1, 1)_{12}$
Temperatura mínima	$SARIMA(0, 0, 0) \times (0, 1, 1)_{12}$
Precipitação	$SARIMA(1, 0, 0) \times (0, 1, 1)_{12}$

Foi realizada a análise da média com relação à amplitude dos dados e nenhuma série necessitou de transformação. As séries não apresentavam tendência e,

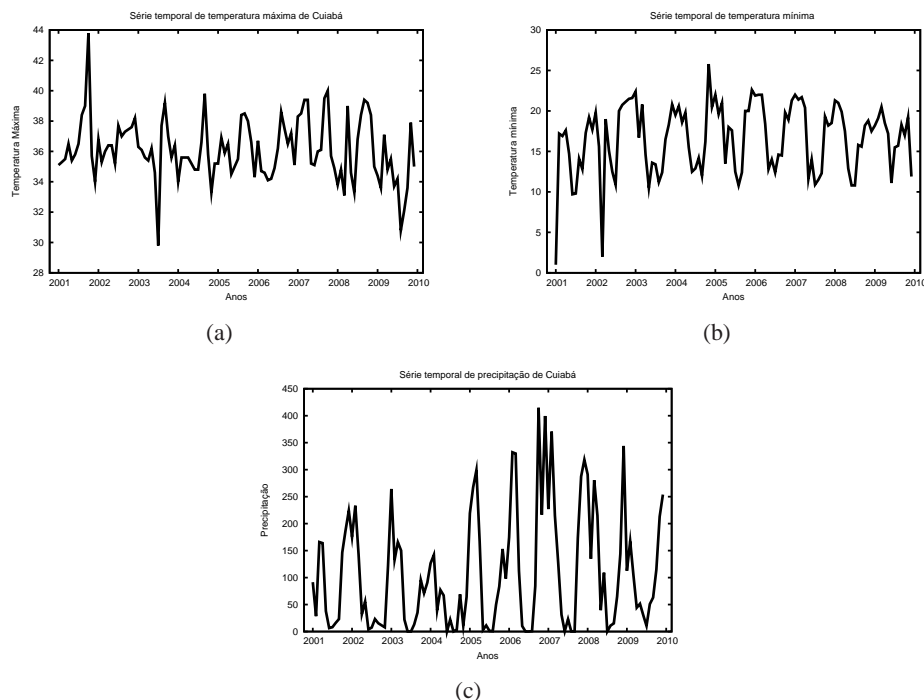


Figura 17 Série Temperatura máxima(a), série de temperatura mínima(b), série de precipitação(c) da cidade de Cuiabá no período de janeiro de 2001 a dezembro de 2009

de acordo com o teste de Fisher, foi feito o estudo da sazonalidade, encontrando-se a necessidade de fazer uma diferença de 12. Após esses ajustes, baseado na metodologia de Box e Jenkins, foram propostos os modelos SARIMA. As análises detalhadas de cada série podem ser vistas no apêndice A.

4.1.3 Modelo de regressão dos resíduos ajustados para cidade de Cuiabá

Após o estudo individual das séries para cidade de Cuiabá, foi encontrado um modelo SARIMA que melhor se ajusta aos dados de cada uma. Feito isso, com o modelo SARIMA estimamos os valores para todas as séries. Foram criadas então quatro novas séries, com os valores reais menos o valor estimado, obtendo

assim os resíduos dos modelos ajustados para cada série em estudo.

O modelo de regressão consistiu na variável dependente como sendo resíduo de casos de dengue e as variáveis independentes sendo os resíduos dos modelos ajustados das variáveis climáticas de Cuiabá, através do método Backward. Iniciou-se o procedimento considerando para todas as co-variáveis defasagem de 1 a 6 meses e posteriormente eliminando as não significativas. De acordo com a Tabela 3, as co-variáveis significativas para o modelo de regressão foram precipitação e temperatura máxima. Com defasagem de 4 meses para temperatura máxima e defasagem de 3 e 5 meses para precipitação.

Tabela 3 Estimativas dos parâmetros do modelo de regressão para Cuiabá-MT

Parâmetro	Coefficiente	Erro Padrão	p-valor
<i>Constante</i>	98,2603	96,0181	0,3090
<i>TemperaturaMaxima_{t-4}</i>	-47,4357	23,1451	0,0435 **
<i>Precipitacao_{t-3}</i>	-1,37109	0,595034	0,0236 **
<i>Precipitacao_{t-5}</i>	1,16675	0,566269	0,0424 **
R^2	0,312083		

Significância ** 0,05

Após o ajuste do modelo foi realizada a análise da independência e da normalidade dos resíduos. Para independência foi feito o teste de Durbin-Watson (2.6.2.5) que apresentou valor 1,803514, que é próximo de 2, confirmando que os resíduos são independentes. A Figura 18 mostra o gráfico do teste de normalidade, que apresenta um *outlier*, o qual foi estudado e representa o grande pico da epidemia de dengue no ano de 2009. Desconsiderando então este valor, mostra-se que os resíduos são normais.

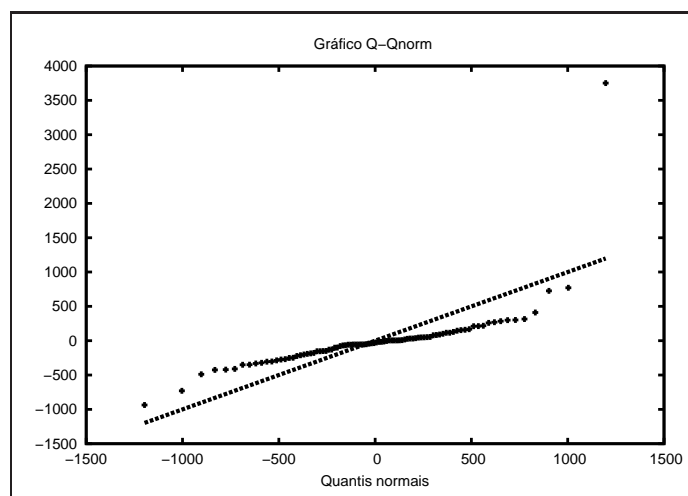


Figura 18 Gráfico da normalidade dos resíduos do modelo ajustado de regressão para a cidade de Cuiabá

4.2 Análise das séries temporais climáticas e casos de dengue da cidade de Lavras - Minas Gerais

4.2.1 Casos de dengue

A Figura 19 apresenta o gráfico da série de casos de dengue da cidade de Lavras e a Figura 20 mostra a função de autocorrelação (ACF) e autocorrelação parcial(PACF) para a série de casos de dengue da cidade de Lavras.

Primeiramente foi feita a análise do comportamento da média com relação à amplitude dos dados para verificar a necessidade de estabilizar a variância. A série foi dividida em 9 grupos de 12 observações consecutivas. Para cada grupo foram calculadas a média e a amplitude. A Figura 21 mostra que a amplitude é diretamente proporcional à média, o que torna necessária a transformação logarítmica em toda a série temporal em estudo. A série original apresentava valores zeros, portanto, foi somado 0.1 para todos os valores.

Após a transformação logarítmica a nova série de casos de dengue está

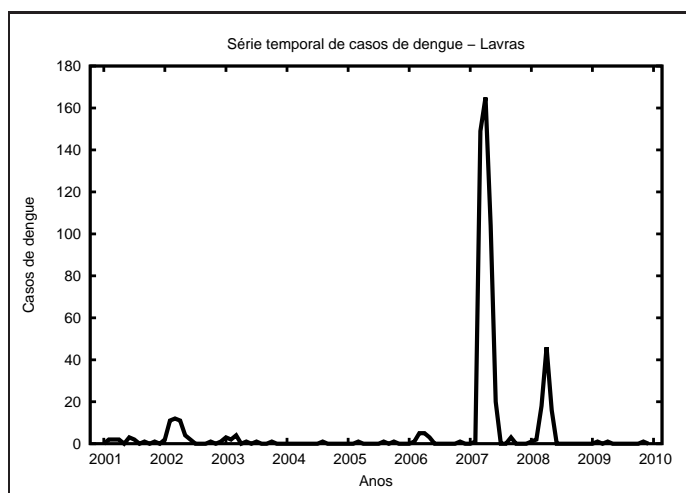


Figura 19 Representação gráfica da série mensal do número de casos de dengue da cidade de Lavras, de janeiro de 2001 a dezembro de 2009

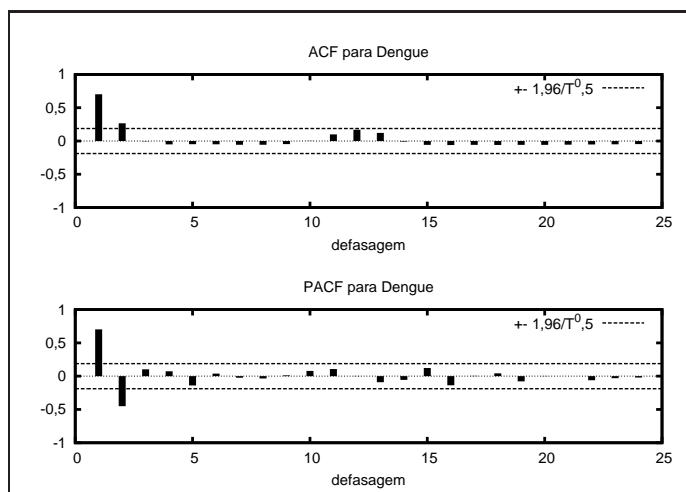


Figura 20 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série do número de casos de dengue da cidade de Lavras

apresentada na Figura 22.

Os gráficos das funções de autocorrelação e autocorrelação parcial da série logaritmizada podem ser vistos na Figura 23.

Visualmente faz-se a suposição da presença da componente sazonalidade e

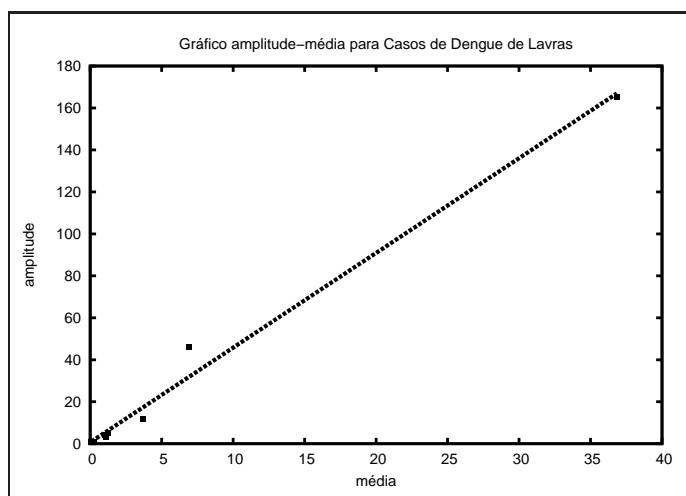


Figura 21 Gráfico da Média x amplitude dos dados da série de casos de dengue da cidade de Lavras de 2001 a 2009




Figura 22 Série mensal do Ln dos casos de dengue da cidade de Lavras no período de janeiro de 2001 a dezembro de 2009

a não ocorrência da componente tendência, mas é necessário confirmar tais informações através de testes matemático-estatísticos. Deve-se aplicar o teste de Fisher, descrito na seção (2.5.2.2), para sazonalidade.

Para isso foi construído um periodograma para verificação da existência de sazonalidade no conjunto de dados. O periodograma da série transformada de

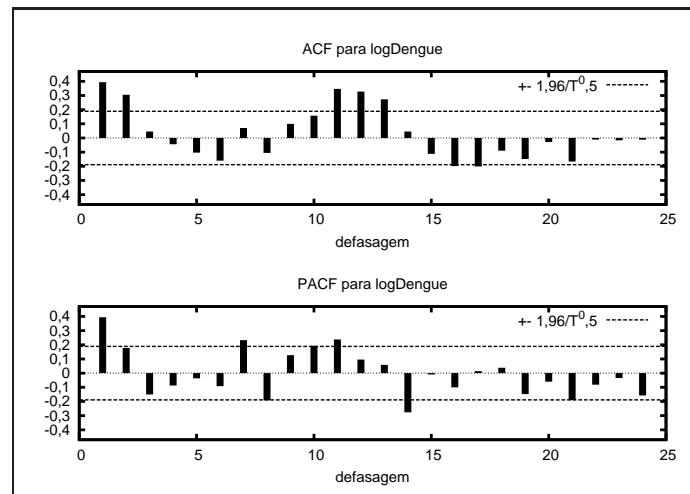


Figura 23 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série mensal \ln do número de casos de dengue da cidade de Lavras

casos de dengue está apresentado na Figura 24.

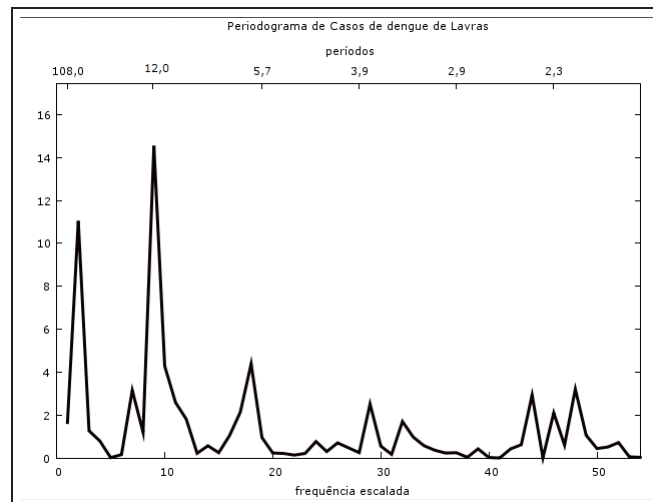


Figura 24 Periodograma de casos de dengue de Lavras, no período de janeiro de 2001 a dezembro de 2009

Pode-se inferir que existe um pico no período igual a 12. Testando então a

existência sazonal no período 12 aplicou-se o teste proposto por Fisher.

$$n = \frac{N}{2} = \frac{108}{2} = 54 \quad \alpha = 0,05$$

$$z_{0,05} = 1 - \left(\frac{0,05}{54} \right)^{\frac{1}{54-2}} = 0,13 \quad g = \frac{11,61}{70,26} = 0,17$$

Como $g > z$, rejeita-se H_0 ao nível de significância $\alpha = 0,05$, isto é, a série transformada apresenta sazonalidade no período analisado.

Mediante as análises preliminares realizadas, confirmou-se que a série não possui tendência e apresenta sazonalidade. Logo, torna-se necessário realizar diferença na série, a fim de torná-la estacionária. Foi aplicada uma diferença na série, de $lag = 12$ para remoção de sazonalidade. (Figura 25)




Figura 25 Série estacionária casos de dengue de Lavras

Após esses ajustes e baseado na metodologia de Box e Jenkins, a identificação do modelo que se ajusta aos dados é realizada através das fac e facp da série estacionária (Figura, 26).

Sendo assim, para a série em questão, foi proposto o seguinte modelo

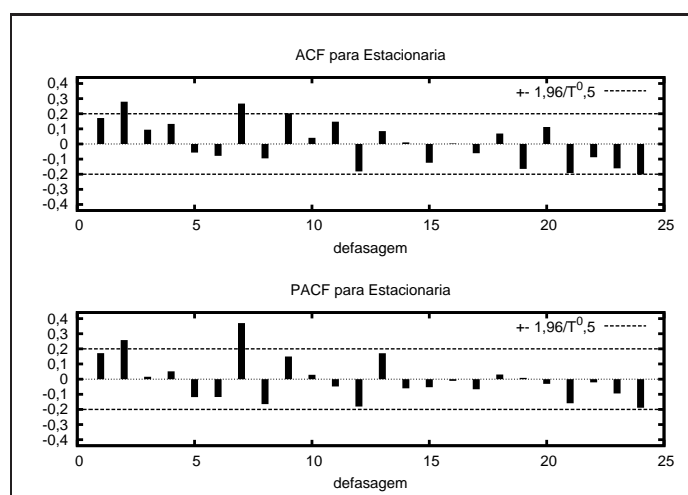


Figura 26 Gráfico da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série estacionária casos de dengue de Lavras

$SARIMA(7, 0, 1) \times (1, 1, 1)_{12}$ incompleto de acordo com a equação 56.

$$(1 - \phi_2 B^2 - \phi_7 B^7)(1 - \Phi_1 B^{12})(1 - B^{12})Z_t = (1 - \theta_1 B)(1 - \Theta_1 B^{12})a_t \quad (56)$$

Na Tabela 4 são apresentadas as estimativas dos parâmetros do modelo 56.

Tabela 4 Estimativas dos parâmetros do modelo $SARIMA(7,0,1) \times (1, 1, 1)_{12}$ e seus respectivos erros padrão, p-valor e valor de Akaike para série do número de casos de dengue da cidade de Lavras - MG

SARIMA(7,0,1)x(1, 1, 1) ₁₂			
Parâmetro	Coefficiente	Erro Padrão	p-valor
ϕ_2	0,307743	0,095233	0,0012 ***
ϕ_7	0,333602	0,095671	0,0005 ***
Φ_1	0,263769	0,120160	0,0282 **
θ_1	0,260794	0,109009	0,0167 **
Θ_1	-0,997865	0,145895	7,17e-012 ***

Critério de Akaike 473,7689

Significância ** 0,05; ***0,01

As análises das funções de autocorrelação e autocorrelação parcial do resíduo do modelo $SARIMA(7, 0, 1) \times (1, 1, 1)_{12}$, conforme Figura 27, não mostram

correlação significativa, com isso, pode-se afirmar que esse modelo ajusta-se aos dados e que o resíduo a_t é ruído branco.

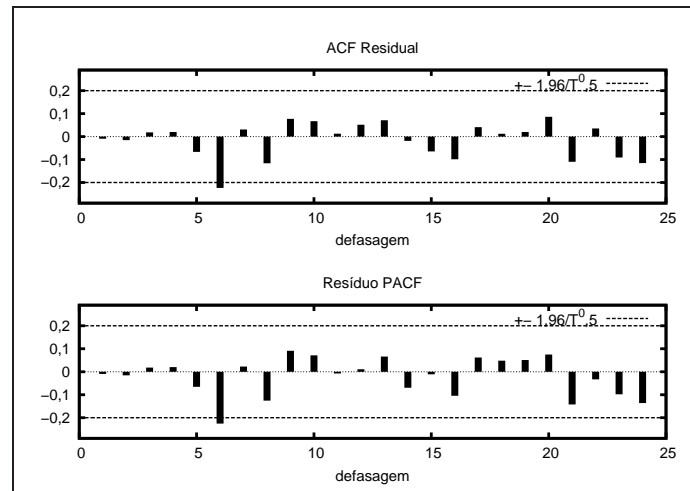


Figura 27 Gráfico da função de autocorrelação (ACF) e autocorrelação parcial (PACF) do resíduo da série Ln de casos de dengue de Lavras

A aplicação do teste de Box-Pierce, visto na seção (2.5.6), forneceu os seguintes resultados:

$$SARIMA(7, 0, 1)(1, 1, 1)_{12} \rightarrow Q_{24} = 16,70 < \chi_{14,0.05}^2 = 23,68 \quad (57)$$

De acordo com 57, confirma-se que a_t é um ruído branco.

4.2.2 Séries climáticas de Lavras

Para cada série climática da cidade de Lavras, utilizamos os mesmos critérios estabelecidos no estudo da série de casos de dengue, vistos na seção anterior. Na Tabela 5 são mostradas as séries climáticas utilizadas nesse estudo. E a Tabela 2 apresenta os modelos SARIMA ajustados para cada série climática da cidade de

Lavras.

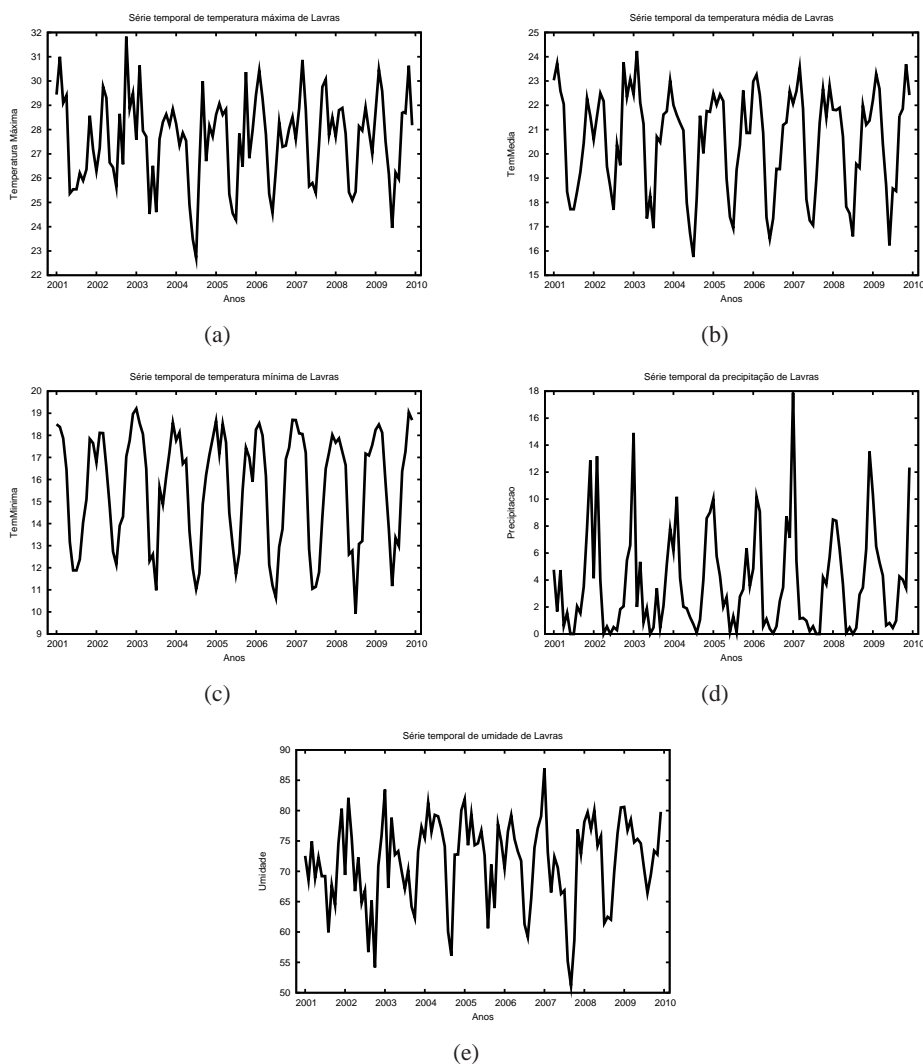


Figura 28 Série Temperatura máxima(a), série de temperatura média(b), série de temperatura mínima(c), série de precipitação(d), série de umidade(e) da cidade de Lavras no período de janeiro de 2001 a dezembro de 2009

Foi realizada para todas as séries a análise da média com relação a amplitude dos dados e nenhuma série precisou de transformação. As séries não apresentavam tendência e, de acordo com o teste de Fisher, foi feito o estudo da sazonalidade.

Tabela 5 Modelos encontrados para as séries climáticas da cidade de Lavras-MG

Série temporal	Modelo SARIMA
Temperatura máxima	$SARIMA(1, 0, 1) \times (2, 1, 0)_{12}$
Temperatura média	$SARIMA(2, 0, 1) \times (2, 1, 0)_{12}$
Temperatura mínima	$SARIMA(2, 0, 1) \times (2, 1, 0)_{12}$
Umidade	$SARIMA(1, 0, 1) \times (1, 1, 1)_{12}$
Precipitação	$SARIMA(0, 0, 1) \times (1, 1, 1)_{12}$

lidade, com uma diferença de 12. Após esses ajustes, baseado na metodologia de Box e Jenkins, foram propostos os modelos SARIMA. As análises detalhadas de cada série podem ser vistas no apêndice B.

4.2.3 Modelo de Regressão para cidade de Lavras em Minas Gerais

Os procedimentos para a obtenção do modelo de regressão para cidade de Lavras foram os mesmos utilizados para Cuiabá. Após o estudo individual das séries para cidade de Lavras, foi encontrado um modelo SARIMA que melhor se ajusta aos dados de cada uma. Feito isso, com o modelo SARIMA estimou-se os valores para todas as séries. Foram criadas então seis novas séries, com os valores reais menos o valor estimado, obtendo assim os resíduos dos modelos ajustados para cada série em estudo.

O modelo de regressão consistiu na variável dependente como sendo resíduo de casos de dengue e as variáveis independentes sendo os resíduos dos modelos ajustados das variáveis climáticas de Lavras, através do método Backward. Iniciou-se o procedimento considerando para todas as co-variáveis defasagem de 1 a 6 meses e posteriormente eliminando as não significativas. De acordo com a Tabela 6, as covariáveis significativas para o modelo de regressão foram temperatura máxima, média, umidade e precipitação. Com defasagem de 4 meses para temperatura máxima e média, defasagem de 6 meses para umidade e defasagens de

2,3 e 4 meses para precipitação. Para o modelo encontrado apenas a temperatura mínima não foi significativa.

Tabela 6 Estimativas dos parâmetros do modelo de regressão para Lavras-MG

Parâmetro	Coefficiente	Erro Padrão	p-valor
<i>Constante</i>	2,58776	4,13920	0,5335
<i>TemperaturaMaxima_{t-4}</i>	6,78627	1,72472	0,0002 ***
<i>TemperaturaMedia_{t-4}</i>	-7,42233	2,25305	0,0014 ***
<i>Umidade_{t-6}</i>	0,472335	0,21198	0,0285 **
<i>Precipitacao_{t-2}</i>	3,16057	0,64735	4,79e-06 ***
<i>Precipitacao_{t-3}</i>	2,88671	0,82626	0,0008 ***
<i>Precipitacao_{t-4}</i>	2,53772	0,68206	0,0004 ***
<i>R²</i>	0,681713		

Significância ** 0,05; ***0,01

Após o ajuste do modelo foi realizada a análise da independência e da normalidade dos resíduos. Para independência foi feito o teste de Durbin-Watson (2.6.2.5) que apresentou valor 1,856275, que é próximo de 2, confirmando que os resíduos são independentes. A Figura 29 mostra o gráfico do teste de normalidade, que apresenta um *outlier*, o qual foi estudado e representa o grande pico da epidemia de dengue no ano de 2007. Desconsiderando então este valor, mostra-se que os resíduos são normais.

Para compararmos com os resultados encontrados para a cidade de Cuiabá, foi proposto um outro modelo de regressão para a cidade de Lavras, utilizando apenas as variáveis que se utilizou para o modelo de Cuiabá. O segundo modelo de regressão consistiu na variável dependente como sendo resíduo do modelo de casos de dengue e as variáveis independentes foram os resíduos dos modelos ajustados para temperatura máxima, mínima e precipitação. Encontrou-se o seguinte modelo, de acordo com a Tabela 7.

Após o ajuste do modelo foi realizada a análise da independência e da normalidade dos resíduos. Para independência foi feito o teste de Durbin-Watson

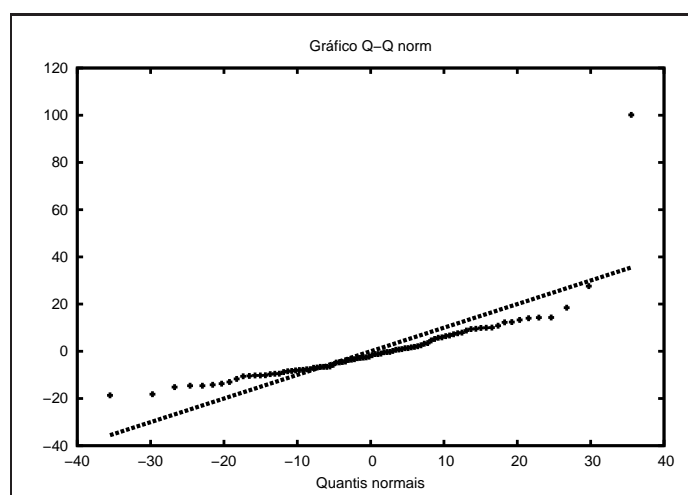


Figura 29 Gráfico da normalidade dos resíduos do modelo ajustado de regressão para a cidade de Lavras

Tabela 7 Estimativas dos parâmetros do segundo modelo de regressão para Lavras-MG

Parâmetro	Coefficiente	Erro Padrão	p-valor
<i>Constante</i>	3,00692	4,09474	0,4647
<i>TemperaturaMaxima_{t-4}</i>	2,54011	0,91542	0,0068 ***
<i>TemperaturaMinima_{t-5}</i>	4,61346	1,61943	0,0055 ***
<i>TemperaturaMinima_{t-6}</i>	3,26139	1,62961	0,0485 **
<i>Precipitacao_{t-2}</i>	3,34233	0,68357	4,65e-06 ***
<i>Precipitacao_{t-3}</i>	3,11080	0,86432	0,0005 ***
<i>Precipitacao_{t-4}</i>	2,35556	0,69902	0,0011 ***
R^2	0,67		

Significância ** 0,05; ***0,01

(2.6.2.5) que apresentou valor 1,859220, que é próximo de 2, confirmando que os dados são independentes. A Figura 30 mostra o gráfico do teste de normalidade, que apresenta um *outlier*, o qual foi estudado e representa o grande pico da epidemia de dengue no ano de 2007. Desconsiderando então este valor, mostra-se que os dados são normais.

O primeiro modelo completo apresenta um R^2 de 0,68 e o segundo modelo para Lavras um R^2 de 0,67. Observando esse valor do R^2 nota-se que a diferença




Figura 30 Gráfico da normalidade dos resíduos do segundo modelo ajustado de regressão para a cidade de Lavras

do primeiro com o segundo é muito pequena, mesmo utilizando duas séries a mais no primeiro modelo.

5 DISCUSSÃO

Neste capítulo são apresentadas as discussões dos modelos encontrados para as cidades de Cuiabá (Mato Grosso) e Lavras (Minas Gerais), de acordo com as revisões de literatura.

5.1 Discussão

A dengue está fortemente relacionada com fatores climáticos. Vários estudos mostram essa relação, Chung e Pang (2002) relataram que a epidemia de dengue está relacionada com as chuvas em Cingapura; Wu et al. (2007) também consideraram que a incidência de dengue associou-se negativamente com a temperatura mensal e estava inversamente relacionada com a umidade relativa do ar em Taiwan.

Para o estudo de Cuiabá encontramos que os casos de dengue estão relacionados com a precipitação e a temperatura máxima. De acordo com Yang et al. (2009), a temperatura ideal para a sobrevivência do mosquito adulto é entre 15 e 30°C. Em Cuiabá a máxima varia entre 29 a 43°C o que pode justificar a influência negativa da temperatura no modelo.

A partir dessas análises das variáveis climáticas pode-se observar que a temperatura é crucial na epidemia de dengue, porque afeta a taxa de desenvolvimento do mosquito em diferentes fases da vida, bem como o desenvolvimento viral da dengue (THU et al., 1998). E neste estudo a temperatura de Cuiabá apresentou maior coeficiente de correlação com os dados.

Estudos em Porto Rico concluíram que os casos de dengue estão positivamente relacionados com a temperatura, mas apenas fracamente associados com chuvas e com o índice de El Niño Southern Oscillation (ENSO) (Jury, 2008). No

México, um estudo mostrou que a incidência de dengue aumenta 2,6% uma semana depois de cada aumento de 1^o C na temperatura máxima e aumentou 1,9% duas semanas depois de cada aumento de 1 cm em precipitação semanal (GUZMAN; KOURI, 2002, HALES et al, 2002).

Para Lavras foram estimados dois modelos, sendo o primeiro utilizando-se as séries climáticas de temperatura máxima, média e mínima, precipitação e umidade. Este modelo apresentou influência positiva da temperatura máxima, umidade, precipitação, e uma influência negativa da temperatura média. A temperatura máxima varia entre 21^o a 31^oC, a faixa ideal para sobrevivência do mosquito. Além disso, a umidade é necessária para a reprodução de mosquitos e precisa ser estudada com alguma atenção.

No Caribe a temperatura também foi estatisticamente significativa na incidência de dengue com atraso de alguns meses (AMARAKOON et. al. 2007). Defasagens similares foram observadas por Wegbreit (1997) em relação à dengue em Trinidad e Tobago. Focks et al. (2003) também têm propostas semelhantes com relação a defasagens e à epidemia de dengue no Sudeste Asiático.

Em termos de comparação, fizemos um modelo utilizando somente as séries de temperatura máxima, mínima e precipitação, como feito para a cidade de Cuiabá e encontramos um modelo em que os casos de dengue tiveram influência positiva de todas as séries climáticas defasadas, temperatura máxima com defasagem 4, temperatura mínima com defasagem 5 e 6 e 2,3 e 4 de defasagem para precipitação. Portanto, os modelos deste trabalho variaram de uma região para outra, porque dependem das séries climáticas, que apresentam valores completamente diferentes para a temperatura máxima, temperatura mínima e a precipitação em cada região.

Além dessas variáveis climáticas, em seus estudos Reiter (1988) observa

que a energia eólica tem influência para o voo e a dispersão de artrópodes, e pode ser responsável pela introdução de um arbovirus em uma área não endêmica, ou por um reaparecimento repentino de um arbovirus, após um período de ausência. Apesar do movimento do ar desempenhar um papel importante no transporte de vetores infectados, o vento também pode reduzir a capacidade de voar do mosquito e o contato com seres humanos (HOFFMANN et.al. 2002). Kennedy (1939), em um dos seus trabalhos, mostrou que a velocidade do vento com mais de 150 cm/seg em um túnel, afeta a capacidade de voar da fêmea do *Aedes aegypti*. Assim, aparentemente, até a velocidade do vento pode reduzir drasticamente a atividade do mosquito e a transmissão da dengue, além das variáveis climáticas utilizadas nesse estudo.

Vários outros trabalhos estão sendo realizados no Brasil e no mundo, destaque-se o estudo de Luz et al. (2008) que utiliza a metodologia de Box e Jenkins para prever a epidemia de dengue no Rio de Janeiro.

Contudo, a relação entre vários fatores climáticos e a dengue permite obter informações para a detecção precoce de epidemia, e assim criar estratégias eficazes para a prevenção da doença (DEPRADINE; LOVELL, 2004).

Além disso, é necessário aumentar e aprofundar este tipo de estudo em outras regiões do Brasil, devido à diversidade climática que nosso país apresenta.

6 CONCLUSÃO

Através de análises de séries temporais verificamos a influência de alguns fatores climáticos na incidência da dengue.

A partir desta primeira análise, foram ajustados modelos de regressão aos resíduos levando em consideração todas as informações disponíveis para cada cidade. Para a cidade de Cuiabá observou-se que a precipitação e a temperatura máxima possuem influência no número de casos de dengue e a temperatura mínima não é significativa.

Já para a cidade de Lavras, além da precipitação e da temperatura máxima, também influenciaram a temperatura média e a umidade. A temperatura mínima também não foi significativa. Portanto, os modelos de regressão ajustados para cada cidade possuem em comum a influência da temperatura máxima e da precipitação, sendo a temperatura máxima com defasagem de quatro meses em ambos os modelos, e a precipitação com defasagem de três e cinco meses para Cuiabá e com defasagem de dois, três e quatro meses para Lavras.

Avaliando os valores dos coeficientes de determinação R^2 , que medem a proporção da variabilidade dos valores observados quando comparados com os valores ajustados, temos que, no caso do modelo de Cuiabá, foi encontrado um R^2 de 0,31 e para Lavras um R^2 de 0,68.

Tendo em vista que os dados disponíveis são distintos para as duas cidades, foi feito um segundo ajuste para a cidade de Lavras considerando apenas as séries disponíveis também para Cuiabá, isto é, temperatura máxima e mínima e precipitação. Neste segundo ajuste, a temperatura máxima continuou influenciando o número de casos de dengue com defasagem de quatro meses e a precipitação com defasagem de dois, três e quatro meses. No entanto, a temperatura mínima passou a ser significativa, com defasagens de cinco e seis meses. O R^2 encontrado foi

de 0,67, mostrando que este novo modelo apesar de levar em conta menos informação, explica tão bem o número de casos de dengue de Lavras quanto o primeiro modelo.

Pode-se observar que, com este tipo de abordagem, não foi possível propor um único modelo que explicasse o comportamento do número de casos de dengue para as duas cidades. Um dos fatores para esta impossibilidade pode estar fortemente relacionado à variabilidade climática observada entre as duas cidades escolhidas para a análise. Apesar de os modelos ajustados serem distintos, ambos possuem um componente comum, que é a influência da temperatura máxima com defasagem de quatro meses. Esta influência pode ser explicada pela relação da biologia do vetor da dengue, o *Aedes aegypti*, com valores de temperatura ideais para o seu desenvolvimento. Estas temperaturas ideais para o desenvolvimento do vetor têm uma média que oscila entre 20⁰ C e 30⁰ C.

Mesmo observando a influência da temperatura com defasagem de 4 meses em ambos os modelos, a precipitação também foi significativa, porém com defasagem de meses diferentes, mas a presença de água é necessária para postura dos ovos e eclosão das larvas do mosquito. Há uma necessidade urgente de melhorar o monitoramento e a previsão da incidência de dengue para a redução da morbidade e mortalidade causada por esta doença.

REFERÊNCIAS

AKAIKE, H. Information theory and an extension of the maximum likelihood principle. In: PETROV, B. N.; CSAKI, F. **Second International Symposium on Information Theory**. Budapest: Akademiai Kiado, 1973.p. 267281.

AMARAKOON, D. et al. Dengue epidemics in the Caribbean-temperature indices to gauge the potential for onset of dengue. **Mitigation and Adaptation Strategies for Global Chang**, New York, v. 13, n. 4, p.341357,2008.

AYOADE, J. O. **Introdução à climatologia para os trópicos**. São Paulo: DIFEL, 1986.

BORROR, D.J.; DELONG, D.M. **Introdução ao estudo dos insetos**. São Paulo: Edgard Blucher,1969.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Times series analysis: forecasting and control**. 3. ed. São Francisco: Holden-Day, 1994.

BOX, G. P.; JENKINS, G. M. **Time series analysis: forecasting and control**. San Francisco: Holden-Day, 1976.

BRANDÃO, A. M. de P. M.; RUSSO, P. R. Qualidade do ar e saúde pública: uma contribuição metodológica. In: **SIMPÓSIO BRASILEIRO DE CLIMATOLOGIA GEOGRÁFICA, 5.**, Curitiba: Contribuições científico-técnicas, UFRP, 2002, p.858-866

CENTRO DE INFORMAÇÕES PARA VIAJANTES - Dengue. **CIVES**, Rio de Janeiro, 2011. Disponível em <<http://www.cives.ufrj.br/informacao/dengue/>>. Acesso em: 2 abr. 2011.

CHARNET, R. et al. **Análise de modelos de regressão linear com aplicações**. Campinas: Unicamp, 1999.

CHUNG, Y.U.K.; PANG, F.L.Y. Dengue virus infection rate in field populations

of female *Aedes aegypti* and *Aedes albopictus* in Singapore. **Tropical medicine and international health, Oxford**, v. 7, n. 4, p. 322- 330, Apr. 2002.

CUPOLLILO, F. et al. Estudo Bioclimatológico Humano: especialização de doenças nas estações chuvosa e seca em Caratinga - MG. In: SIMPÓSIO BRASILEIRO DE CLIMATOLOGIA GEOGRÁFICA, 4., 2000, Rio de Janeiro. **Anais**. Rio de Janeiro: UFRJ, 2000. p.105.

DEPRADINE, C. A.; LOVELL, E.H. Climatological variables and the incidence of dengue fever in Barbados. **International journal of environmental health research**, Abingdon. v. 14, n. 6, p.429-441, July/Sept. 2004.

DONALISIO, M. R. **O dengue no espaço habitado**. São Paulo: Hucitec, 1999

FIGUEIREDO, L. T. M.; CAVALCANTE, S. M. B.; SIMÕES, M. C. A dengue serologic survey of school children in Rio de Janeiro, Brazil, 1986 and 1987. **Bulletin of the Pan American Health Organization**, Washington, v. 24, n. 2, p.217-225, 1990.

FOCKS, D.A, et al. Early warning systems for dengue in Indonesia and Thailand. PROCEEDINGS OF THE ANNUAL CONFERENCE, 2003, Albuquerque. **Unified science e technology for reducing biological threats e countering terrorism**. Albuquerque, 2003.

GLASSER, C. M. **Estudo da infecção do estado de São Paulo por *Aedes Aegypti* e *Aedes albopictus***. 1997. 93 f. Dissertação (Mestrado em Saúde Pública) - Faculdade de Saúde Pública da USP, São Paulo, 1997.

GUBLER, D. J. Dengue and dengue hemorrhagic fever: its history and resurgence as a global health problem. In: GUBLER, D. J.; KUNO, G. (Ed.). **Dengue and dengue hemorrhagic fever**. New York: CAB International, 1997. p. 1-22.

GUBLER, D. J. Dengue and dengue hemorrhagic fever. **Clinical microbiology reviews**, Washington, v. 11, n. 3, p. 480-496, July 1998.

GUBLER, D.J. Dengue e dengue hemorrhagic fever: the emergence of a global

health problem. **Emerging Infectious Disease**, Atlanta, v. 1, n. 2, p. 55-57, Apr. 1995.

GUZMÁN, M. G.; KOURÍ, G. Dengue: an update. **The Lancet Infectious Diseases**. Oxford, v. 2, n. 1, p. 33-42, Jan. 2002.

HALES, S. et al. Potential effect of population and climate changes on global distribution of dengue fever an empirical model. **The Lancet**, London, v. 360, n. 9336, p. 830-834, Sept. 2002.

HALSTEAD, S. B. Dengue. **The Lancet**, London, v. 370, n. 9599, p.1644-1652, Nov. 2007.

HALSTEAD, S. B. Epidemiology of dengue and dengue hemorrhagic fever. In: GUBLER, D. J. e KUNO, G.. (Ed.). **Dengue and dengue hemorrhagic fever**. New York: CAB International, 1997, p. 23-44.

HELLPACH, W. **Geopsique: o homem, o tempo, o clima, o solo e a paisagem: psicologia maior**. São Paulo: Paulinas, 1967.

HOFFMANN, E. J, MILLER, J. R. Reduction of mosquito (Diptera: Culicidae) attacks on a human subject by combination of wind and vapor-phase DEET repellent. **Journal of medical entomology**, Lanham, v. 39, n. 6, p. 935 – 938, Nov. 2002.

JURY, M. R. Climate influence on dengue epidemics in Puerto Rico. **International Journal of Environmental Health Research**. Abingdon, v. 18, n. 5, p.323 – 334, Oct. 2008.

KENNEDY, J. S. The visual responses of flying mosquitoes. **Proceedings of the Zoological Society of London**, London, v. 109, p. 221 – 242, 1939.

KÖPPEN, W. **Climatology con un estudio delos climas de la tierra**. México: Fondo de Cultura Econômica, 1948.

KUNO, G. Factors influencing the transmission of dengue viruses. In: GUBLER,

D. J.; KUNO, G. (Ed.). **Dengue and dengue hemorrhagic fever**. New York: CAB International, 1997. p. 61 – 87.

LOMBARDO, M. A. **A ilha de calor nas Metr p les: o exemplo S o Paulo**. S o Paulo: Hucitec, 1985

LUZ P. M. et al. Time series analysis of dengue incidence in Rio de Janeiro, Brazil. **The American society of tropical medicine and hygiene**, Baltimore, v.79, n.6, p. 933-939, DEC. 2008.

MINIST RIO DA SA DE. Funda o Nacional de Sa de. **Dengue: instru es para pessoal de combate ao vetor: manual de normas t cnicas**. 3. ed. rev. Bras lia: Minist rio da Sa de, 2001.

MINIST RIO DA SA DE. Funda o Nacional de Sa de. Secretaria de Vigil ncia em Sa de. **Diagn stico r pido nos munic pios para vigil ncia entomol gica do Aedes aegypti no Brasil LIRAA: metodologia para avalia o dos  ndices de Breteau e Predial**. Bras lia: Minist rio da Sa de, 2005.

MINIST RIO DA SA DE. Secretaria de Vigil ncia em Sa de. Balan o dengue janeiro a julho de 2011. **Portal da Sa de**, Bras lia, 2011. Dispon vel em: <www.saude.gov.br>. Acesso em: 15 jul. 2011.

MORETTIN, P. A.; TOLOI, C. M. C. **An lise de s ries temporais**. 2. ed. S o Paulo: Edgard Bl cher, 2006.

NAKHAPAKORN, K. TRIPATHI, N. K. An information value-based analysis of physical and climatic factors affecting dengue fever and dengue hemorrhagic fever incidence. **International Journal of Health Geographics**, Assen, v. 4, p. 1 – 13, Jan. 2005.

ORGANIZA O MUNDIAL DA SA DE. **Mejoramiento de la labor de los agentes de salud comunitarios en la atenci n primaria de salud**. Geneva: Organiza o Mundial da Sa de, 1987.

PRIESTLEY, M. B. **Spectral analysis and time series**. New York: Academic, 1989.

REITER, P. Weather, vector biology and arboviral recrudescence. In: MONATH, T.P, (Ed.). **Arboviruses: epidemiology and ecology: volume I**. Boca Raton: CRC, 1988. p. 245-255.

REY, L. **Parasitologia**. 2. ed. Rio de Janeiro: Guanabara Koogan, 1991.

RODHAIN, F. ROSEN, L. Mosquito vectors and dengue virus-vector relationships. In: GUBLER, D.J, KUNO, G. **Dengue and dengue hemorrhagic fever**. New York: CAB International; 1997, p. 45 – 60.

SANTŠANNA NETO, J. L. Clima e organizaão do espao. **Boletim de geografia**. Maring. n.16, p. 119 – 131, 1998.

SCHATZMAYR, H.; NOGUEIRA, R.; ROSA, A. P.T. da. An outbreak of dengue virus at Rio de Janeiro. **Memrias do Instituto Oswaldo Cruz**, So Paulo, v. 81, n. 2, p. 245 – 246, Apr./Jun. 1986.

SCHMIDT, R. **Voc e a meteorologia: acertos, erros e dicas**. Porto Alegre: Sagra, 1994.

TEIXEIRA, M. G.; BARRETO M. L.; GUERRA, Z. Epidemiologia e medidas de preveno da dengue. **Informe Epidemiolgico do SUS**, Braslia, v. 8 n. 4, p.5 – 33, 1999.

THU, H. M. ; AYE, K. M.; THEIN, S. The effect of temperature and humidity on dengue virus propagation in *Aedes aegypti* mosquitos. **Southeast Asian Journal of Tropical Medicine and Public Health**. Thailand, v. 29, n. 3, p. 280 – 284, Sept. 1998.

WEGBREIT, J. The possible effects of temperature and precipitation on dengue morbidity in Trinidad and Tobago: a retrospective longitudinal study. In: **POPULATION environmental dynamics: issues and policy**. Michigan: School of Natural Resources and the Environment, 1997.

WORD HEALTH ORGANIZATION. Dengue. **WHO**, New York, 2011.
Disponvel em: <<http://www.who.int/topics/dengue/en/>>. Acesso em: 15 maio

2011.

WU, P. C. et al. Weather as an effective predictor for occurrence of dengue fever in Taiwan. **Acta Tropical**. Taiwan, v. 103, n. 1, p. 50 – 57, July 2007.

YANG, H. M. et al. Assessing the effects of temperature on the population of *Aedes aegypti*, the vector of dengue. **Epidemiology and infection**, Cambridge, v. 137, n. 8, p. 188 – 202, Feb. 2009.

APÊNDICE A

São apresentados os resultados das análises das variáveis climáticas para cidade de Cuiabá, Mato Grosso. Para cada série climática utilizamos os mesmos critérios estabelecidos na série de casos de dengue.

Temperatura máxima

A Figura 31 apresenta o gráfico dos dados da série de temperatura máxima da cidade de Cuiabá. E a Figura 32 mostra a função de autocorrelação (ACF) e autocorrelação parcial(PACF) para a série de temperatura máxima da cidade de Cuiabá.




Figura 31 Representação gráfica da série mensal de temperatura máxima da cidade de Cuiabá, de janeiro de 2001 a dezembro de 2009

Primeiramente foi feita a análise do comportamento da média com relação à amplitude dos dados para verificar a necessidade de estabilizar a variância, a série foi dividida em 9 grupos de 12 observações consecutivas. Para cada grupo foram calculadas a média e a amplitude, a Figura (33) mostra que a amplitude não é proporcional à média, o que não torna necessária a transformação dos dados.

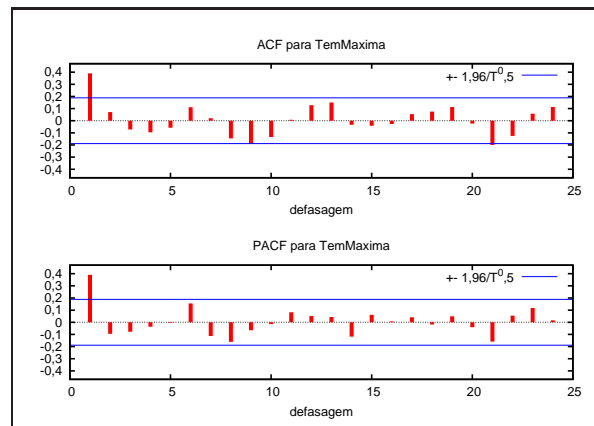


Figura 32 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série de temperatura máxima da cidade de Cuiabá

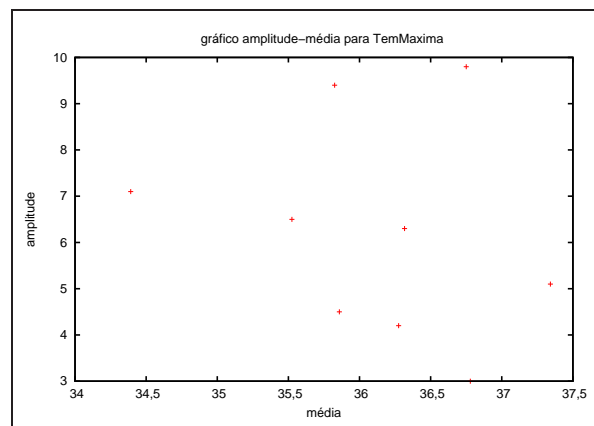


Figura 33 Média x amplitude dos dados de temperatura máxima da cidade de Cuiabá

Visualmente faz-se a suposição da presença da componente sazonalidade e a não ocorrência da componente tendência, mas é necessário confirmar tais informações através de testes matemático-estatísticos. Deve-se aplicar o teste de Fisher, descrito na seção (2.5.2.2), para sazonalidade e a ausência da tendência pode ser percebida pela função de autocorrelação, que mostra que a função cai rapidamente para zero.

Para isso foi construído um periodograma para verificação da existência de sazonalidade no conjunto de dados. O periodograma da série de temperatura

máxima está apresentado na Figura 34.

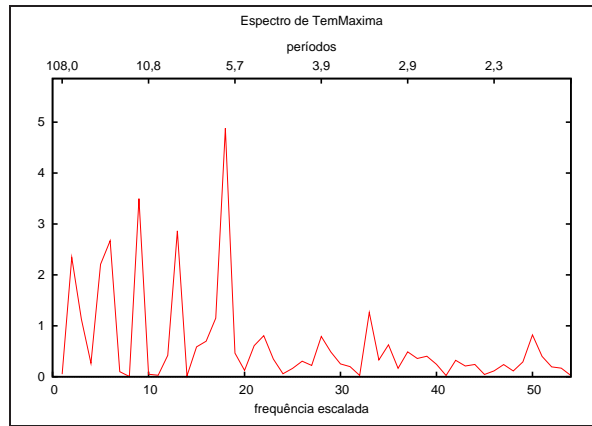


Figura 34 Periodograma de temperatura máxima de Cuiabá

Pode-se a partir da Figura 34 inferir que a série possui uma periodicidade em $p = 6$ e $p = 12$, iremos desconsiderar o período 6, testando então a existência sazonal no período 12 aplicou-se o teste proposto por Fisher.

$$n = \frac{N}{2} = \frac{108}{2} = 54 \quad \alpha = 0,05$$

$$z_{0,05} = 1 - \left(\frac{0,05}{54} \right)^{\frac{1}{54-2}} = 0,13 \quad g = \frac{3,5}{25,01} = 0,14$$

Como $g > z$, rejeita-se H_0 ao nível de significância $\alpha = 0,05$, isto é, a série apresenta sazonalidade no período 12.

Mediante as análises preliminares realizadas, confirmou-se que a série possui não tendência e apresenta sazonalidade no período 12. Logo, torna-se necessário realizar diferença na série, a fim de torná-la estacionária. Foi aplicada uma diferença na série, sendo de $lag = 12$ para remoção de sazonalidade. (Figura 35)

Após esses ajustes, e baseado na metodologia de Box & Jenkins, a identificação do modelo que se ajusta aos dados é realizada através das *fac* e *facp* (Figura




Figura 35 Série estacionária de temperatura máxima de Cuiabá

36) da série estacionária.

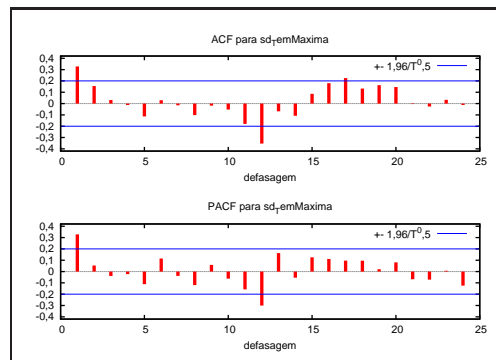


Figura 36 Função de autocorrelação (ACF) da série estacionária de temperatura máxima de Cuiabá

Sendo assim, para a série em estudo, foi proposto o seguinte modelo $SARIMA(1, 0, 0)(0, 1, 1)_{12}$ de acordo com a equação abaixo.

$$(1 - \phi_1 B)(1 - B^{12})Z_t = (1 - \Theta_{12} B^{12})a_t \quad (58)$$

Na Tabela 8 são apresentadas as estimativas dos parâmetros do modelo 58.

As análises das funções de autocorrelação e autocorrelação parcial (Figura 37) do resíduo do modelo $SARIMA(1, 0, 0)(0, 1, 1)_{12}$, não mostra correlação

Tabela 8 Estimativas dos parâmetros do modelo $SARIMA(1,0,0) \times (0,1,1)_{12}$ e seus respectivos erros padrão para série de temperatura máxima da cidade de Cuiabá - MT

$SARIMA(1,0,0) \times (0,1,1)_{12}$		
Parâmetro	Coefficiente	Erro Padrão
ϕ_1	0,318468	0,09642
Θ_1	-0,91177	0,30866

significativa, com isso, pode-se afirmar que esse modelo ajusta-se aos dados e que o resíduo a_t é ruído branco.

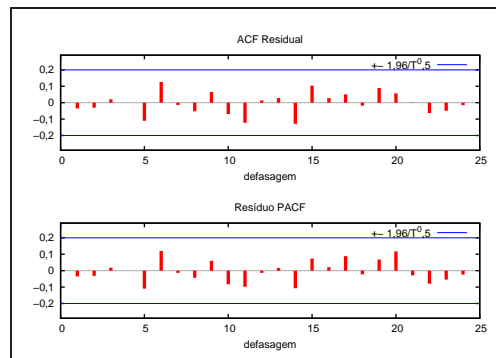


Figura 37 Função de autocorrelação do resíduo da série de temperatura máxima de Cuiabá

A aplicação do teste de Box-Pierce forneceu os seguintes resultados:

$$SARIMA(1,0,0)(0,1,1)_{12} \rightarrow Q_{24} = 29,20 < \chi_{23,0.05}^2 = 35,17 \quad (59)$$

De acordo com 59, confirmou-se que a_t é um ruído branco.

Temperatura Mínima

A Figura 38 apresenta o gráfico dos dados da série de temperatura mínima da cidade de Cuiabá. E a Figura 39 mostra a função de autocorrelação (ACF) e autocorrelação parcial(PACF) para a série de temperatura mínima da cidade de Cuiabá. A (fac) não decai rapidamente para zero, indicando que a série não é

estacionária.




Figura 38 Representação gráfica da série mensal de temperatura mínima da cidade de Cuiabá, de janeiro de 2001 a dezembro de 2009

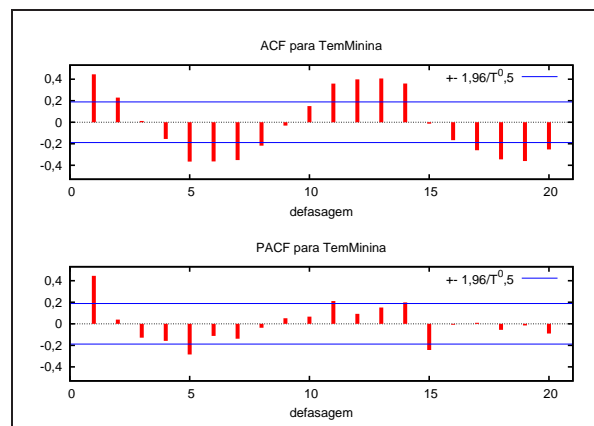


Figura 39 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da temperatura mínima da cidade de Cuiabá

Primeiramente foi feita a análise do comportamento da média com relação à amplitude dos dados para verificar a necessidade de estabilizar a variância, a série foi dividida em 9 grupos de 12 observações consecutivas. Para cada Grupo foram calculadas a média e a amplitude; a Figura 40 mostra que a amplitude não é proporcional à média, o que nos mostra que não é necessário a transformação dos dados.




Figura 40 Média vs amplitude dos dados de temperatura mínima da cidade de Cuiabá

Visualmente faz-se a suposição da presença da componente sazonalidade e a não ocorrência da componente tendência, mas é necessário confirmar tais informações através de testes matemático-estatísticos. Deve-se aplicar o teste de Fisher, para sazonalidade e a ausência da tendência pode ser percebida pela função de autocorrelação, que mostra que a função cai rapidamente para zero.

Para isso foi construído um periodograma para verificação da existência de sazonalidade no conjunto de dados. O periodograma da temperatura mínima está apresentado na Figura 41.




Figura 41 Periodograma de temperatura mínima de Cuiabá

Pode-se inferir que existe um pico no período igual a 12, testando então a existência sazonal neste período aplicou-se o teste proposto por Fisher e tem-se

$$n = \frac{N}{2} = \frac{108}{2} = 54 \quad \alpha = 0,05$$

$$z_{0,05} = 1 - \left(\frac{0,05}{54} \right)^{\frac{1}{54-1}} = 0,12 \quad g = \frac{53,95}{156,01} = 0,35$$

Como $g > z$, rejeita-se H_0 ao nível de significância $\alpha = 0,05$, isto é, a série apresenta sazonalidade no período analisado.

Mediante as análises preliminares realizadas, confirmou-se que a série não possui tendência e apresenta sazonalidade. Logo, torna-se necessário realizar diferença na série, a fim de torná-la estacionária. Foi aplicada uma diferença na série, sendo na $lag = 12$ para eliminação da sazonalidade. (Figura 42)




Figura 42 Série estacionária de temperatura mínima de Cuiabá

Após esses ajustes, e baseado na metodologia de Box & Jenkins, a identificação do modelo que se ajusta aos dados é realizada através das fac e $fapc$ da série estacionária (Figura 43).

Sendo assim, para a série em questão, foi proposto o seguinte modelo




Figura 43 Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de temperatura mínima da cidade de Cuiabá

$SARIMA(0, 0, 0)(0, 1, 1)_{12}$, de acordo com a equação abaixo.

$$(1 - B^{12})Z_t = (1 - \Theta_{12}B^{12})a_t \quad (60)$$

Na Tabela 9 são apresentadas as estimativas dos parâmetros do modelo 68.

Tabela 9 Estimativas dos parâmetros do modelo $SARIMA(0,0,0)x(0, 1, 1)_{12}$ e seus respectivos erros padrão para série de temperatura mínima da cidade de Cuiabá - MT

SARIMA(0,0,0)x(0, 1, 1) ₁₂		
Parâmetro	Coefficiente	Erro Padrão
Θ_1	-0,620571	0,129145

As funções de autocorrelação e autocorrelação parcial do resíduo do modelo $SARIMA(0, 0, 0)(0, 1, 1)_{12}$, conforme Figura 44, não possuem correlação significativa, ou seja, pode-se afirmar que esse modelo ajusta-se aos dados e que o resíduo a_t é ruído branco.

A aplicação do teste de Box-Pierce forneceu os seguintes resultados

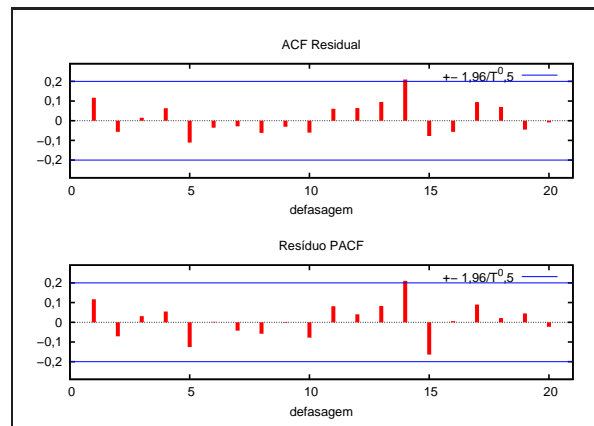


Figura 44 Fac e Facp residual do modelo temperatura mínima da cidade de Cuiabá

$$SARIMA(0, 0, 0)(0, 1, 1)_{12} \rightarrow Q_{24} = 16,30 < \chi_{22,0.05}^2 = 33,92 \quad (61)$$

De acordo com 61, confirmou-se que at é um ruído branco mesmo contendo um "lag" fora do intervalo de confiança, o que é permitido 5% das "lags" fora do intervalo.

Precipitação

A Figura 45 apresenta o gráfico dos dados da série de precipitação da cidade de Cuiabá. A série original apresentava valores zeros, então foi somado 0,1 para todos os valores. E a Figura 46 mostra a função de autocorrelação (ACF) e autocorrelação parcial(PACF) para a série de precipitação de Cuiabá. A (ACF) não decaiu rapidamente para zero, indicando que a série não é estacionária.

Primeiramente foi feita a análise do comportamento da média com relação à amplitude dos dados para verificar a necessidade de estabilizar a variância, a série foi dividida em 9 grupos de 12 observações consecutivas. Para cada grupo foram




Figura 45 Representação gráfica da série mensal da precipitação da cidade de Cuiabá, de janeiro de 2001 a dezembro de 2010

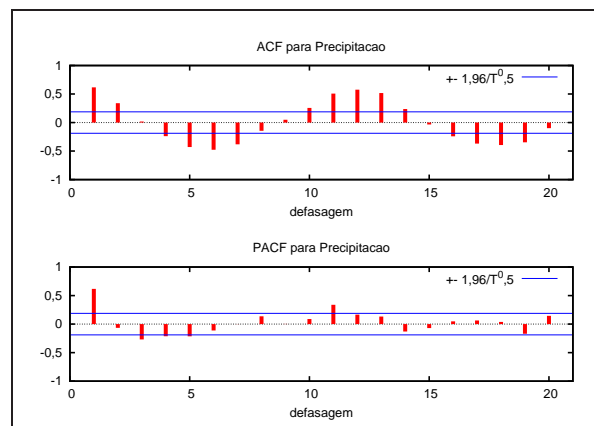


Figura 46 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série de precipitação da cidade de Cuiabá

calculadas a média e a amplitude; a Figura (47) mostra que a amplitude é diretamente proporcional à média, o que torna necessário a transformação logarítmica em toda a série temporal em estudo.

Após a transformação logarítmica, a nova série de precipitação está apresentado na Figura (48).

A função de autocorrelação e autocorrelação parcial da série logaritimizada pode ser vista na Figura (49).




Figura 47 Média vs amplitude dos dados da série de precipitação da cidade de Cuiabá




Figura 48 Série mensal do Ln da precipitação da cidade de Cuiabá

Visualmente faz-se a suposição da presença da componente sazonalidade e a não ocorrência da componente tendência, mas é necessário confirmar tais informações através de testes matemático-estatísticos. Deve-se aplicar o teste de Fisher, descrito na seção (2.5.2.2), para sazonalidade e a ausência da tendência pode ser percebida pela função de autocorrelação, que mostra que a função cai rapidamente para zero.

Para isso foi construído um periodograma para verificação da existência de sazonalidade no conjunto de dados. O periodograma da série de precipitação de

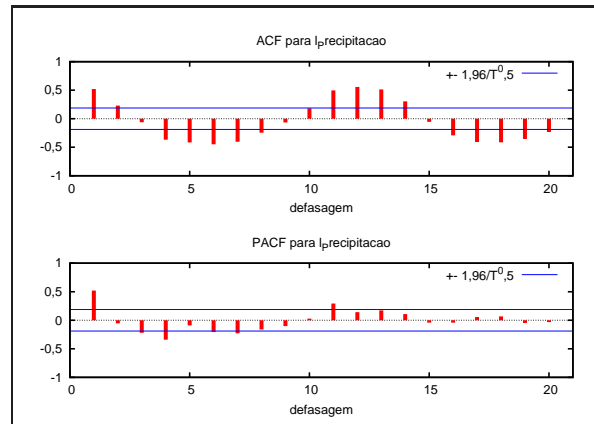


Figura 49 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série mensal \ln da precipitação da cidade de Cuiabá

Cuiabá está apresentado na Figura 50.

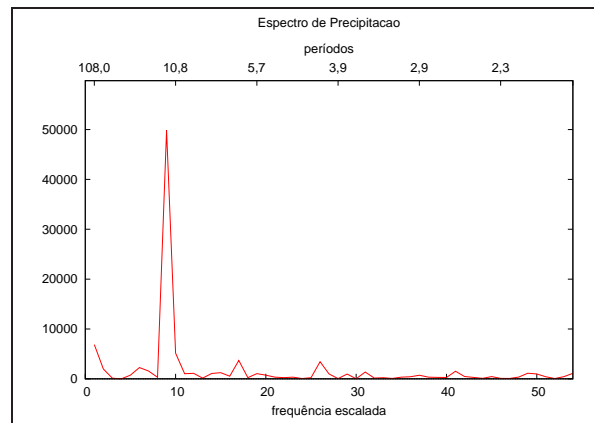


Figura 50 Periodograma da precipitação de Cuiabá

Pode-se inferir que existe um pico no período 12. Testando então a existência sazonal neste período aplicou-se o teste proposto por Fisher têm-se:

$$n = \frac{N}{2} = \frac{108}{2} = 54 \quad \alpha = 0,05$$

$$z_{0,05} = 1 - \left(\frac{0,05}{54} \right)^{\frac{1}{54-1}} = 0,12 \quad g = \frac{22,77}{44,71} = 0,51$$

Como $g > z$, rejeita-se H_0 ao nível de significância $\alpha = 0,05$, isto é, a série transformada apresenta sazonalidade no período analisado.

Mediante as análises preliminares realizadas, confirmou-se que a série possui não tendência e apresenta sazonalidade. Logo, torna-se necessário realizar diferenças na série, a fim de torná-la estacionária. Foi aplicada uma diferença na série, sendo de $lag = 12$ para eliminação da sazonalidade. (Figura 51).




Figura 51 Série estacionária da precipitação de Cuiabá

Após esses ajustes, e baseado na metodologia de Box & Jenkins, a identificação do modelo que se ajusta aos dados é realizada através das *fac* e *facp* da série estacionária (Figura 52).

Sendo assim, para a série em questão foi proposto o seguinte modelo $SARIMA(1, 0, 0)(0, 1, 1)_{12}$, de acordo com a equação abaixo.

$$(1 - \phi_1 B)(1 - B^{12})Z_t = (1 - \Theta_1 B)a_t \quad (62)$$

Na Tabela 10, são apresentadas as estimativas dos parâmetros do modelo 62.

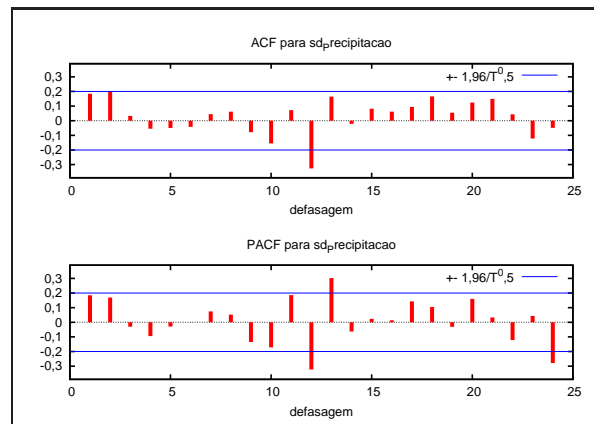


Figura 52 Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de precipitação da cidade de Cuiabá

Tabela 10 Estimativas dos parâmetros do modelo $SARIMA(1,0,0) \times (0,1,1)_{12}$ e seus respectivos erros padrão para série de precipitação da cidade de Cuiabá - MT

SARIMA(1,0,0) \times (0,1,1) ₁₂		
Parâmetro	Coefficiente	Erro Padrão
ϕ_1	0,389674	0,0971718
Θ_1	-0,802367	0,149382

As análises das funções de autocorrelação e autocorrelação parcial do resíduo do modelo $SARIMA(1,0,0)(0,1,1)_{12}$, conforme Figura 53, mostra correlação significativa, mas pode-se afirmar que esse modelo ajusta-se aos dados e que o resíduo a_t é ruído branco.

A aplicação do teste Box-Pierce, forneceu os seguintes resultados:

$$SARIMA(1,0,0)(0,1,1)_{12} \rightarrow Q_{24} = 26,29 < \chi_{22,0.05}^2 = 33,92 \quad (63)$$

De acordo com 63, confirmou-se que a_t é um ruído branco mesmo contendo um "lag" fora do intervalo de confiança, o que é permitido 5% das "lags" fora do intervalo.

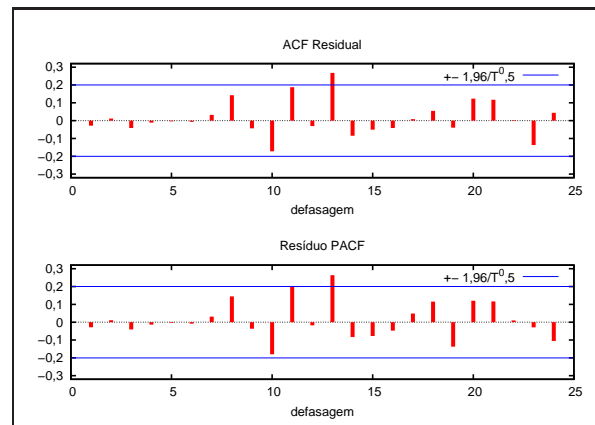


Figura 53 Função de autocorrelação e autocorrelação parcial do resíduo da série de precipitação de Cuiabá

APÊNDICE B

São apresentados os resultados das análises das variáveis climáticas para cidade de Lavras, Minas Gerais. Para cada série climática utilizamos os mesmos critérios estabelecidos na série de casos de dengue.

Temperatura máxima

A Figura 54 apresenta o gráfico dos dados da série de temperatura máxima da cidade de Lavras. E a Figura 55 mostra a função de autocorrelação (ACF) e autocorrelação parcial(PACF) para a série de temperatura máxima da cidade de Lavras.




Figura 54 Representação gráfica da série mensal de temperatura máxima da cidade de Lavras, de janeiro de 2001 a dezembro de 2009

Primeiramente foi feita a análise do comportamento da média com relação à amplitude dos dados para verificar a necessidade de estabilizar a variância, a série foi dividida em 9 grupos de 12 observações consecutivas. Para cada grupo foram calculadas a média e a amplitude; a Figura (56) mostra que a amplitude não é proporcional à média, o que não torna necessária a transformação dos dados.

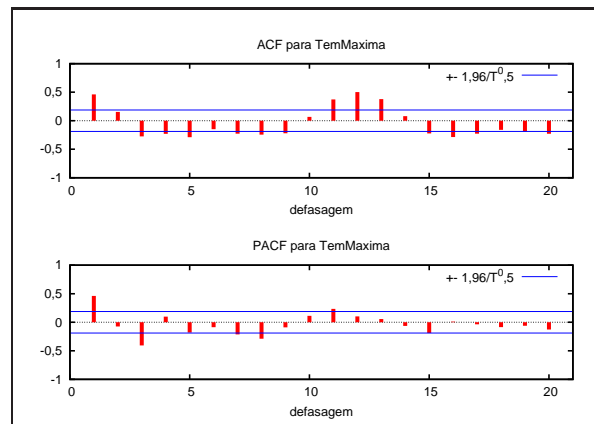


Figura 55 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série de temperatura máxima da cidade de Lavras




Figura 56 Média vs amplitude dos dados de temperatura máxima da cidade de Lavras

Visualmente faz-se a suposição da presença da componente sazonalidade e a não ocorrência da componente tendência, mas é necessário confirmar tais informações através de testes matemático-estatísticos. Deve-se aplicar o teste de Fisher, descrito na seção (2.5.2.2), para sazonalidade e a ausência da tendência pode ser percebida pela função de autocorrelação, que mostra que a função cai rapidamente para zero.

Para isso foi construído um periodograma para verificação da existência de sazonalidade no conjunto de dados. O periodograma da série de temperatura

máxima está apresentado na Figura 57.




Figura 57 Periodograma de temperatura máxima de Lavras

Pode-se a partir da Figura 57 inferir que a série possui uma periodicidade em $p = 12$; testando então a existência sazonal neste período, aplicou-se o teste proposto por Fisher.

$$n = \frac{N}{2} = \frac{108}{2} = 54 \quad \alpha = 0,05$$

$$z_{0,05} = 1 - \left(\frac{0,05}{54} \right)^{\frac{1}{54-1}} = 0,12 \quad g = \frac{11,2}{28,2} = 0,40$$

Como $g > z$, rejeita-se H_0 ao nível de significância $\alpha = 0,05$, isto é, a série de temperatura máxima apresenta sazonalidade no período 12.

Mediante as análises preliminares realizadas, confirmou-se que a série possui não tendência e apresenta sazonalidade no período 12. Logo, torna-se necessário realizar diferença na série, a fim de torná-la estacionária. Foi aplicada uma diferença na série, sendo de $lag = 12$ para remoção de sazonalidade (Figura 58).

Após esses ajustes e baseado na metodologia de Box & Jenkins, a identificação do modelo que se ajusta aos dados é realizada através das *fac* e *facp* da série




Figura 58 Série estacionária de temperatura máxima de Lavras

estacionária (Figura 59).

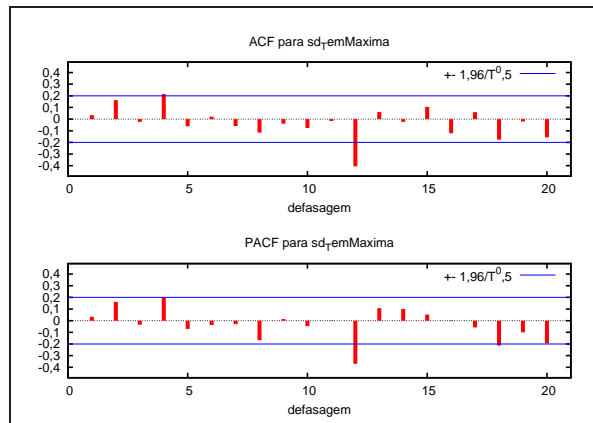


Figura 59 Função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série estacionária de temperatura máxima de Lavras

Sendo assim, para a série em estudo, foi proposto o seguinte modelo $SARIMA(1, 0, 1)(2, 1, 0)_{12}$ de acordo com a equação abaixo.

$$(1 - \phi_1 B)(1 - \Phi_1 B - \Phi_2 B^2)(1 - B^{12})Z_t = (1 - \theta_1 B)a_t \quad (64)$$

Na Tabela 11 são apresentadas as estimativas dos parâmetros do modelo

64.

Tabela 11 Estimativas dos parâmetros do modelo $SARIMA(1,0,1) \times (2,1,0)_{12}$ e seus respectivos erros padrão para série de temperatura máxima da cidade de Lavras - MG

SARIMA(7,0,1) × (1, 1, 1) ₁₂		
Parâmetro	Coefficiente	Erro Padrão
ϕ_1	0,693029	0,192540
Φ_1	-0,766502	0,0972291
Φ_2	-0,496706	0,0943400
θ_1	-0,504062	0,214370

As análises das funções de autocorrelação e autocorrelação parcial (Figura 60) do resíduo do modelo $SARIMA(1, 0, 1)(2, 1, 0)_{12}$, não mostra correlação significativa, com isso, pode-se afirmar que esse modelo ajusta-se aos dados e que o resíduo a_t é ruído branco.

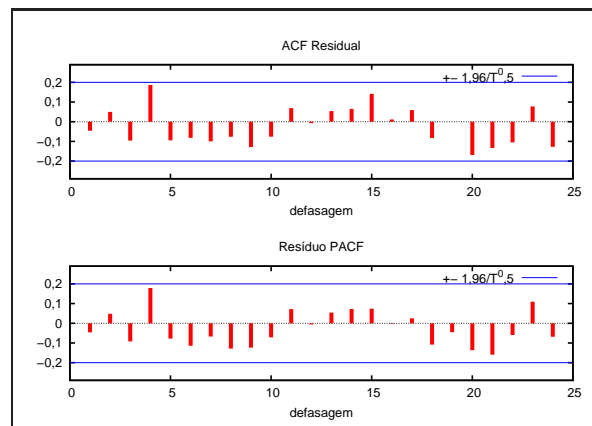


Figura 60 Função de autocorrelação e autocorrelação parcial do resíduo da série de temperatura máxima de Lavras

A aplicação do teste de Box-Pierce, visto na seção (2.5.6), forneceu os seguintes resultados:

$$SARIMA(1, 0, 1)(0, 1, 1)_{12} \rightarrow Q_{24} = 25,73 < \chi_{20,0.05}^2 = 31,41 \quad (65)$$

De acordo com 65, confirmou-se que at é um ruído branco.

Temperatura Média

A Figura 61 apresenta o gráfico dos dados da série de temperatura média da cidade de Lavras. E a Figura 62 mostra a função de autocorrelação (ACF) e autocorrelação parcial(PACF) para a série de temperatura média da cidade de Lavras. A (ACF) não decai rapidamente para zero, indicando que a série não é estacionária.




Figura 61 Representação gráfica da série mensal de temperatura média da cidade de Lavras, de janeiro de 2001 a dezembro de 2009

Primeiramente foi feita a análise do comportamento da média com relação à amplitude dos dados para verificar a necessidade de estabilizar a variância, a série foi dividida em 9 grupos de 12 observações consecutivas. Para cada grupo foram calculadas a média e a amplitude, a Figura (63) mostra que a amplitude não é proporcional à média, o que nos mostra que não é necessária a transformação dos dados.

Visualmente faz-se a suposição da presença da componente sazonalidade e a não ocorrência da componente tendência, mas é necessário confirmar tais infor-

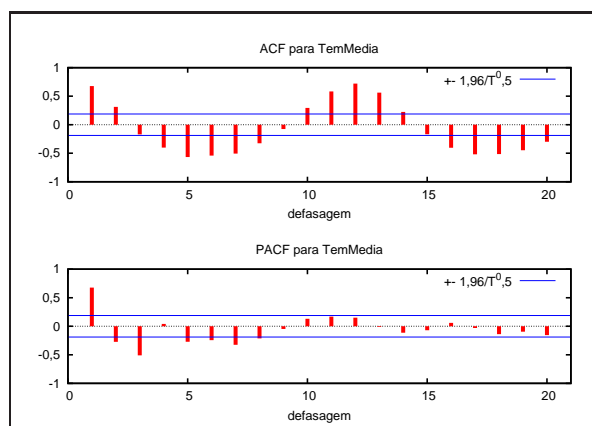


Figura 62 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da temperatura média da cidade de Lavras




Figura 63 Média vs amplitude dos dados de temperatura média da cidade de Lavras

mações através de testes matemático-estatísticos. Deve-se aplicar o teste de Fisher, descrito na seção (2.5.2.2), para sazonalidade e a ausência da tendência pode ser percebida pela função de autocorrelação, que mostra que a função cai rapidamente para zero.

Para isso foi construído um periodograma para verificação da existência de sazonalidade no conjunto de dados. O periodograma da temperatura média está apresentado na Figura 64.

Pode-se inferir que existe um pico no período igual a 12. Testando então a




Figura 64 Periodograma de temperatura média da cidade de Lavras

existência sazonal neste período aplicou-se o teste proposto por Fisher e tem-se

$$n = \frac{N}{2} = \frac{108}{2} = 54 \quad \alpha = 0,05$$

$$z_{0,05} = 1 - \left(\frac{0,05}{54} \right)^{\frac{1}{54-1}} = 0,12 \quad g = \frac{27,34}{38,42} = 0,71$$

Como $g > z$, rejeita-se H_0 ao nível de significância $\alpha = 0,05$, isto é, a série apresenta sazonalidade no período analisado.

Mediante as análises preliminares realizadas, confirmou-se que a série possui não tendência e apresenta sazonalidade. Logo, torna-se necessário realizar diferença na série, a fim de torná-la estacionária. Foi aplicada uma diferença na série, sendo de $lag = 12$ para eliminação da sazonalidade (Figura 65).

Após esses ajustes, e baseado na metodologia de Box & Jenkins, a identificação do modelo que se ajusta aos dados é realizada através das *fac* e *fapc* da série estacionária (Figura 66).

Sendo assim, para a série em questão, foi proposto o seguinte modelo




Figura 65 Série estacionária de temperatura média da cidade de Lavras

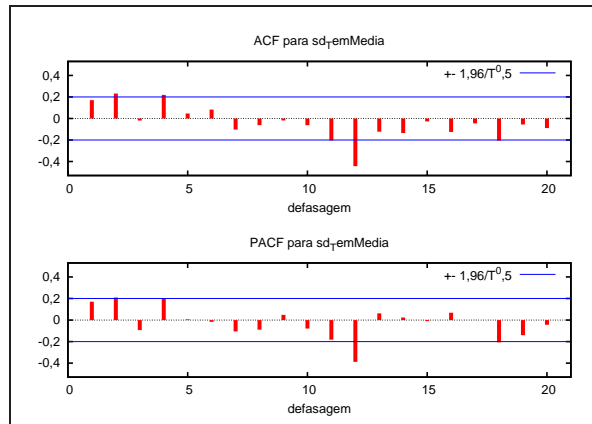


Figura 66 Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de temperatura média da cidade de Lavras

$SARIMA(2, 0, 1)(2, 1, 0)_{12}$ de acordo com a equação abaixo.

$$(1 - \phi_1 B - \phi_2 B^2)(1 - \Phi_1 B - \Phi_2 B^2)(1 - B^{12})Z_t = (1 - \theta_1 B)a_t \quad (66)$$

Na Tabela 12 são apresentadas as estimativas dos parâmetros do modelo 66.

As análises das funções de autocorrelação e autocorrelação parcial do resíduo do modelo $SARIMA(2, 0, 1)(2, 1, 0)_{12}$, conforme Figura 67, não possuem

Tabela 12 Estimativas dos parâmetros do modelo $SARIMA(2,0,1) \times (2,1,0)_{12}$ e seus respectivos erros padrão para série de temperatura média da cidade de Lavras - MG

SARIMA(2,0,1)x(2,1,0) ₁₂		
Parâmetro	Coefficiente	Erro Padrão
ϕ_1	-0,456874	0,160013
ϕ_2	0,390873	0,108007
Φ_1	-0,751015	0,0941167
Φ_2	-0,543410	0,0910439
θ_1	0,654544	0,140517

correlação significativa, com isso, pode-se afirmar que esse modelo ajusta-se aos dados e que o resíduo a_t é ruído branco.

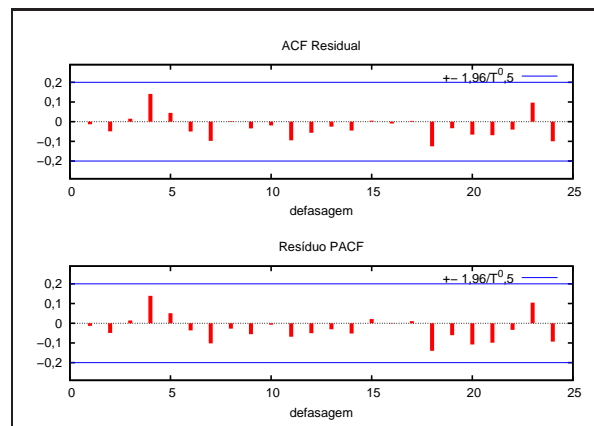


Figura 67 Função de autocorrelação e autocorrelação parcial do resíduo do modelo da série de temperatura média de Lavras

A aplicação do teste de Box-Pierce, visto na seção (2.5.6), forneceu os seguintes resultados

$$SARIMA(2,0,1)(0,1,1)_{12} \rightarrow Q_{24} = 11,5095 < \chi_{19,0.05}^2 = 30,14 \quad (67)$$

De acordo com 67, confirmou-se que a_t é um ruído branco.

Temperatura Mínima

A Figura 68 apresenta o gráfico dos dados da série de temperatura mínima da cidade de Lavras. E a Figura 69 mostra a função de autocorrelação (ACF) e autocorrelação parcial (PACF) para a série de temperatura mínima da cidade de Lavras. A (ACF) não decai rapidamente para zero, indicando que a série não é estacionária.




Figura 68 Representação gráfica da série mensal de temperatura mínima da cidade de Lavras, de janeiro de 2001 a dezembro de 2009

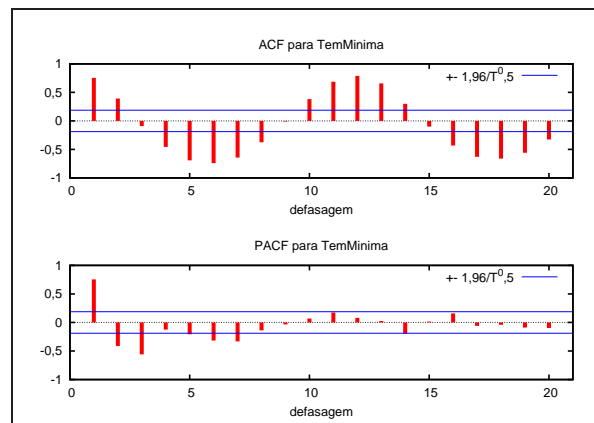


Figura 69 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da temperatura mínima da cidade de Lavras

Primeiramente foi feita a análise do comportamento da média com relação à amplitude dos dados para verificar a necessidade de estabilizar a variância, a série foi dividida em 9 grupos de 12 observações consecutivas. Para cada Grupo foram calculadas a média e a amplitude, a Figura 70 mostra que a amplitude não é proporcional à média, o que nos mostra que não é necessário a transformação dos dados.




Figura 70 Média vs amplitude dos dados de temperatura mínima da cidade de Lavras

Visualmente faz-se a suposição da presença da componente sazonalidade e a não ocorrência da componente tendência, mas é necessário confirmar tais informações através de testes matemático-estatísticos. Deve-se aplicar o teste de Fisher, descrito na seção (2.5.2.2), para sazonalidade e a ausência da tendência pode ser percebida pela função de autocorrelação, que mostra a função cai rapidamente para zero.

Para isso foi construído um periodograma para verificação da existência de sazonalidade no conjunto de dados. O periodograma da temperatura mínima está apresentado na Figura 71.

Pode-se inferir que existe um pico no período igual a 12. Testando então a existência sazonal neste período aplicou-se o teste proposto por Fisher, e têm-se




Figura 71 Periodograma de temperatura mínima de Lavras

$$n = \frac{N}{2} = \frac{108}{2} = 54 \quad \alpha = 0,05$$

$$z_{0,05} = 1 - \left(\frac{0,05}{54}\right)^{\frac{1}{54-1}} = 0,12 \quad g = \frac{48,47}{57,47} = 0,84$$

Como $g > z$, rejeita-se H_0 ao nível de significância $\alpha = 0,05$, isto é, a série apresenta sazonalidade no período analisado.

Mediante as análises preliminares realizadas, confirmou-se que a série não possui tendência e apresenta sazonalidade. Logo, torna-se necessário realizar diferença na série, a fim de torná-la estacionária. Foi aplicada uma diferença na série, sendo na $lag = 12$ para eliminação da sazonalidade (Figura 72).

Após esses ajustes, e baseado na metodologia de Box & Jenkins, a identificação do modelo que se ajusta aos dados é realizada através das fac e facp da série estacionária (Figura 73).

Sendo assim, para a série em questão foi proposto o seguinte modelo $SARIMA(2, 0, 1)(2, 1, 0)_{12}$ de acordo com a equação abaixo.

$$(1 - \phi_1 B - \phi_2 B^2)(1 - \Phi_1 B - \Phi_2 B^2)(1 - B^{12})Z_t = (1 - \theta_1 B)a_t \quad (68)$$




Figura 72 Série estacionária de temperatura mínima de Lavras

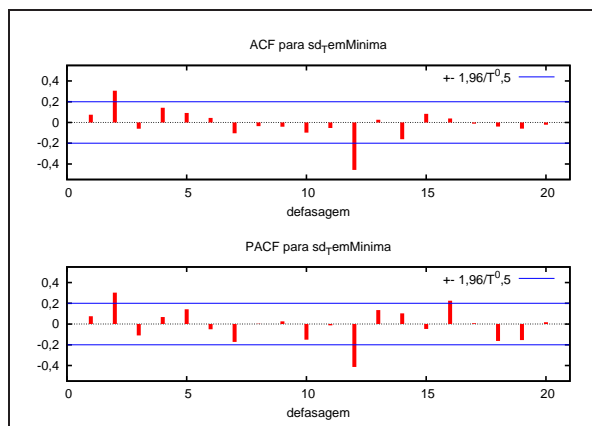


Figura 73 Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de temperatura mínima da cidade de Lavras

Na Tabela 13 são apresentadas as estimativas dos parâmetros do modelo 68.

As funções de autocorrelação e autocorrelação parcial do resíduo do modelo $SARIMA(2, 0, 1)(2, 1, 0)_{12}$, conforme Figura 74, não possuem correlação significativa, ou seja, pode-se afirmar que esse modelo ajusta-se aos dados e que o resíduo a_t é ruído branco.

A aplicação do teste de Box-Pierce, visto na seção (2.5.6), forneceu os

Tabela 13 Estimativas dos parâmetros do modelo SARIMA(2,0,1)x(2,1,0)₁₂ e seus respectivos erros padrão para série de temperatura mínima da cidade de Lavras - MG

SARIMA(2,0,1)x(2,1,0) ₁₂		
Parâmetro	Coefficiente	Erro Padrão
ϕ_1	-0,431496	0,191848
ϕ_2	0,342664	0,0995301
Φ_1	-0,825958	0,101849
Φ_2	-0,457089	0,0976074
θ_1	0,580903	0,189732

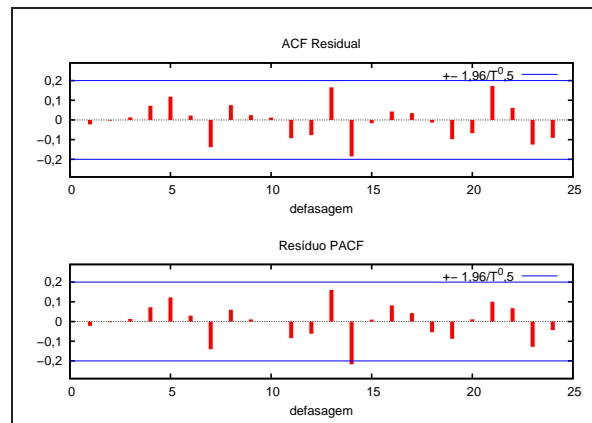


Figura 74 Fac e Facp residual do modelo temperatura mínima da cidade de Lavras

seguintes resultados

$$SARIMA(2, 0, 0)(0, 1, 1)_{12} \rightarrow Q_{24} = 22,9441 < \chi_{19,0.05}^2 = 30,14 \quad (69)$$

De acordo com 69, confirmou-se que at é um ruído branco.

Precipitação

A Figura 75 apresenta o gráfico dos dados da série de precipitação da cidade de Lavras. E a Figura 76 mostra a função de autocorrelação (ACF) e autocorrelação parcial(PACF) para a série de precipitação de Lavras. A (ACF) não

decai rapidamente para zero, indicando que a série não é estacionária.




Figura 75 Representação gráfica da série mensal da precipitação da cidade de Lavras, de janeiro de 2001 a dezembro de 2010

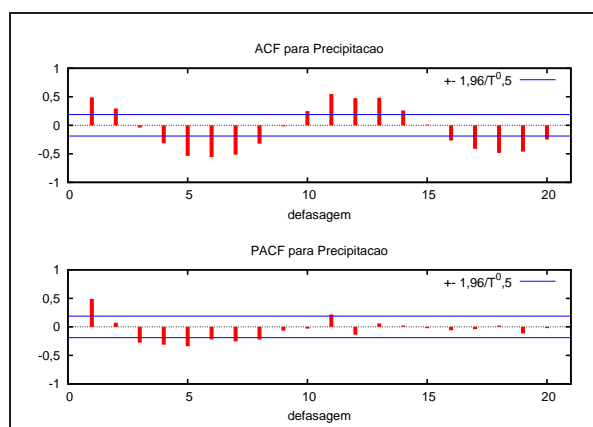


Figura 76 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série de precipitação da cidade de Lavras

Primeiramente foi feita a análise do comportamento da média com relação à amplitude dos dados para verificar a necessidade de estabilizar a variância, a série foi dividida em 9 grupos de 12 observações consecutivas. Para cada grupo foram calculadas a média e a amplitude, a Figura (77) mostra que a amplitude não é proporcional à média, o que não torna necessária a transformação logarítmica em toda a série temporal em estudo.




Figura 77 Média x amplitude dos dados da série de precipitação da cidade de Lavras

Visualmente faz-se a suposição da presença da componente sazonalidade e a não ocorrência da componente tendência, mas é necessário confirmar tais informações através de testes matemático-estatísticos. Deve-se aplicar o teste de Fisher, descrito na seção (2.5.2.2), para sazonalidade e a ausência da tendência pode ser percebida pela função de autocorrelação, que mostra a função cai rapidamente para zero.

Para isso foi construído um periodograma para verificação da existência de sazonalidade no conjunto de dados. O periodograma da série da série transformada de precipitação de Lavras está apresentado na Figura 78.

Pode-se inferir que existe um pico no período 12. Testando então a existência sazonal neste período aplicou-se o teste proposto por Fisher e tem-se:

$$n = \frac{N}{2} = \frac{108}{2} = 54 \quad \alpha = 0,05$$

$$z_{0,05} = 1 - \left(\frac{0,05}{54} \right)^{\frac{1}{54-1}} = 0,12 \quad g = \frac{77,59}{124,16} = 0,62$$

Como $g > z$, rejeita-se H_0 ao nível de significância $\alpha = 0,05$, isto é, a série transformada apresenta sazonalidade no período analisado.




Figura 78 Periodograma da precipitação de Lavras

Mediante as análises preliminares realizadas, confirmou-se que a série possui não tendência e apresenta sazonalidade. Logo, torna-se necessário realizar diferenças na série, a fim de torná-la estacionária. Foi aplicada uma diferença na série, sendo de $lag = 12$ para eliminação da sazonalidade (Figura 79).




Figura 79 Série estacionária da precipitação de Lavras

Após esses ajustes e baseado na metodologia de Box & Jenkins, a identificação do modelo que se ajusta aos dados é realizada através das *fac* e *facp* da série estacionária (Figura 80).

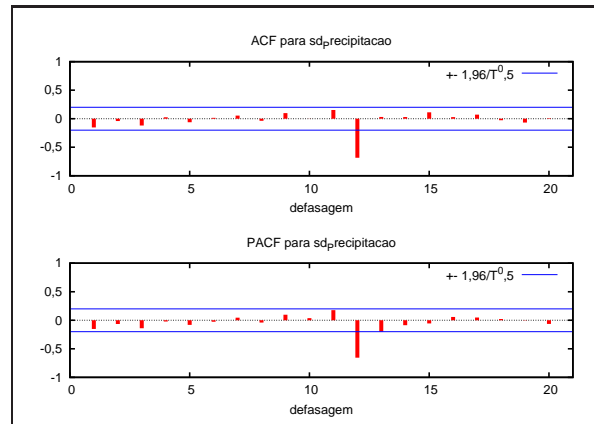


Figura 80 Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de precipitação da cidade de Lavras

Sendo assim, para a série em questão, foi proposto o seguinte modelo $SARIMA(0, 0, 1)(1, 1, 1)_{12}$, de acordo com a equação abaixo.

$$(1 - \Phi_1 B)(1 - B^{12})Z_t = (1 - \Theta_1 B)a_t \quad (70)$$

Na Tabela 14 são apresentadas as estimativas dos parâmetros do modelo 70.

Tabela 14 Estimativas dos parâmetros do modelo $SARIMA(0,0,1)x(1, 1, 1)_{12}$ e seus respectivos erros padrão para precipitação da cidade de Lavras - MG

SARIMA(0,0,1)x(1, 1, 1) ₁₂		
Parâmetro	Coefficiente	Erro Padrão
<i>const</i>	0,110323	0,0568849
Φ_1	-0,447006	0,119641
θ_1	-0,251876	0,113922
Θ_1	-0,693354	0,205100

As análises das funções de autocorrelação e autocorrelação parcial do resíduo do modelo $SARIMA(0, 0, 1)(1, 1, 1)_{12}$, conforme figura 81, não mostra correlação significativa, com isso, pode-se afirmar que esse modelo ajusta-se aos dados e que o resíduo a_t é ruído branco.

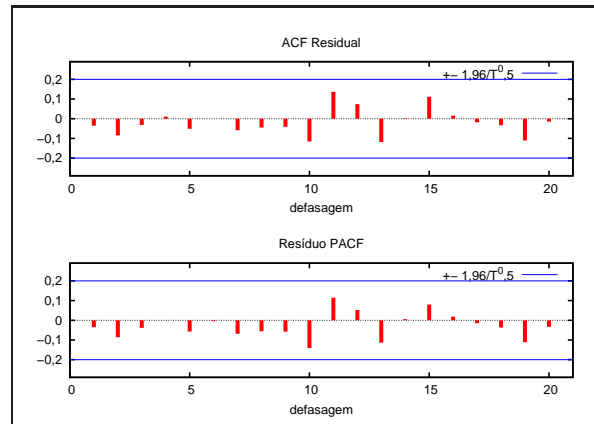


Figura 81 Função de autocorrelação e autocorrelação parcial do resíduo da série de precipitação de Lavras

A aplicação do teste Box-Pierce, visto na seção (2.5.6), forneceu os seguintes resultados:

$$SARIMA(0, 0, 1)(1, 1, 1)_{12} \rightarrow Q_{24} = 13,30 < \chi_{22,0.05}^2 = 33,92 \quad (71)$$

De acordo com 71, confirmou-se que a_t é ruído branco.

Umidade

A Figura 82 apresenta o gráfico dos dados da série de umidade da cidade de Lavras. E a Figura 83 mostra a função de autocorrelação (ACF) e autocorrelação parcial(PACF) para a série de umidade de Lavras. A (ACF) não decai rapidamente para zero, indicando que a série não é estacionária.

Primeiramente foi feita a análise do comportamento da média com relação à amplitude dos dados para verificar a necessidade de estabilizar a variância, a série foi dividida em 9 grupos de 12 observações consecutivas. Para cada grupo foram calculadas a média e a amplitude, a Figura (84) mostra que a amplitude não




Figura 82 Representação gráfica da série mensal da umidade relativa do ar da cidade de Lavras, de janeiro de 2001 a dezembro de 2010

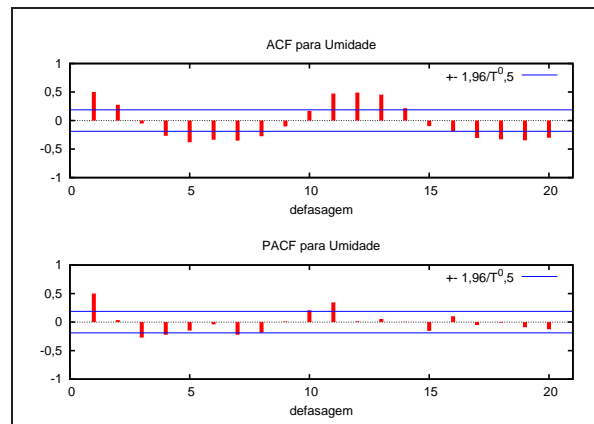


Figura 83 Representação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série de umidade relativa do ar da cidade de Lavras

é proporcional à média, o que não torna necessário a transformação logarítmica em toda a série temporal em estudo.

Visualmente faz-se a suposição da presença da componente sazonalidade e a não ocorrência da componente tendência, mas é necessário confirmar tais informações através de testes matemático-estatísticos. Deve-se aplicar o teste de Fisher, descrito na seção (2.5.2.2), para sazonalidade e a ausência da tendência, pode ser percebida pela função de autocorrelação, que mostra que a função cai rapidamente




Figura 84 Média vs amplitude dos dados da série de umidade da cidade de Lavras

para zero.

Para isso foi construído um periodograma para verificação da existência de sazonalidade no conjunto de dados. O periodograma da série transformada de precipitação de Lavras está apresentado na Figura 85.




Figura 85 Periodograma da umidade de Lavras

Pode-se inferir que existe um pico no período 12. Testando então a existência sazonal neste período aplicou-se o teste proposto por Fisher e tem-se:

$$n = \frac{N}{2} = \frac{108}{2} = 54 \quad \alpha = 0,05$$

$$z_{0,05} = 1 - \left(\frac{0,05}{54} \right)^{\frac{1}{54-1}} = 0,12 \quad g = \frac{199,72}{427,7} = 0,47$$

Como $g > z$, rejeita-se H_0 ao nível de significância $\alpha = 0,05$, isto é, a série transformada apresenta sazonalidade no período analisado.

Mediante as análises preliminares realizadas, confirmou-se que a série possui não tendência e apresenta sazonalidade. Logo, torna-se necessário realizar diferenças na série, a fim de torná-la estacionária. Foi aplicada uma diferença na série, sendo de $lag = 12$ para eliminação da sazonalidade. (Figura 86)




Figura 86 Série estacionária da umidade de Lavras

Após esses ajustes, e baseado na metodologia de Box e Jenkins, a identificação do modelo que se ajusta aos dados é realizada através das *fac* e *facp* da série estacionária (Figura 87).

Sendo assim, para a série em questão foi proposto o seguinte modelo $SARIMA(1, 0, 1)(1, 1, 1)_{12}$ de acordo com a equação abaixo.

$$(1 - \phi_1 B)(1 - \Phi_1 B)(1 - B^{12})Z_t = (1 - \theta_1 B)(1 - \Theta_1 B)a_t \quad (72)$$

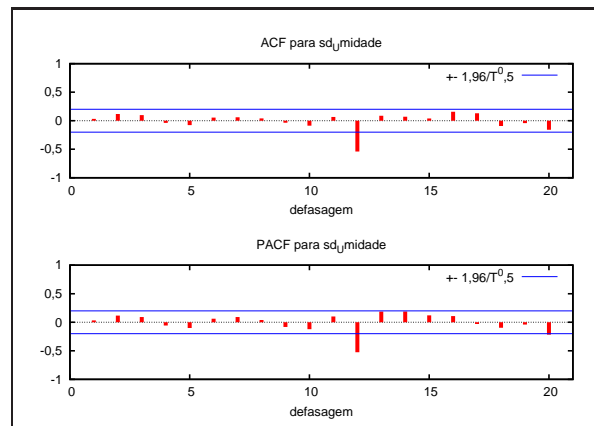


Figura 87 Função de autocorrelação(ACF) e autocorrelação parcial (PACF) da série estacionária de umidade da cidade de Lavras

Na Tabela 15 são apresentadas as estimativas dos parâmetros do modelo 72.

Tabela 15 Estimativas dos parâmetros do modelo $SARIMA(1,0,1) \times (1,1,1)_{12}$ e seus respectivos erros padrão para série de umidade da cidade de Lavras - MG

SARIMA(1,0,1) \times (1,1,1) $_{12}$		
Parâmetro	Coefficiente	Erro Padrão
ϕ_1	0,890056	0,139352
Φ_1	-0,243836	0,130441
θ_1	-0,720082	0,189021
Θ_1	-0,753282	0,153747

As análises das funções de autocorrelação e autocorrelação parcial do resíduo do modelo $SARIMA(1,0,1)(1,1,1)_{12}$, conforme Figura 88, não mostra correlação significativa, com isso, pode-se afirmar que esse modelo ajusta-se aos dados e que o resíduo a_t é ruído branco.

A aplicação do teste Box-Pierce, visto na seção (2.5.6), forneceu os seguintes resultados:

$$SARIMA(1,0,1)(1,1,1)_{12} \rightarrow Q_{24} = 12,8931 < \chi_{20,0.05}^2 = 31,41 \quad (73)$$

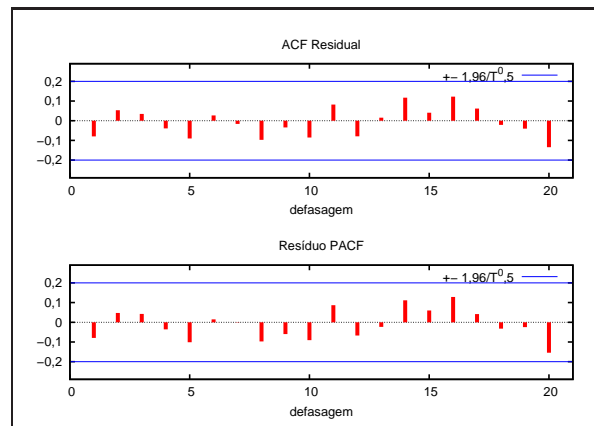


Figura 88 Função de autocorrelação e autocorrelação parcial do resíduo da série de umidade de Lavras

De acordo com 73, confirmou-se que a_t é ruído branco.