

**UNIVERSIDADE FEDERAL DE MATO GROSSO
INSTITUTO DE FÍSICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL**

**PREVISÃO MICROMETEOROLÓGICA NO
PANTANAL MATO-GROSSENSE PELA TEORIA DE
SISTEMAS DINÂMICOS**

GEISON JADER MELLO

Orientador: Prof. Dr. Marcelo Sacardi Biudes

**Cuiabá, MT
Dezembro de 2013**

**UNIVERSIDADE FEDERAL DE MATO GROSSO
INSTITUTO DE FÍSICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL**

**PREVISÃO MICROMETEOROLÓGICA NO
PANTANAL MATO-GROSSENSE PELA TEORIA DE
SISTEMAS DINÂMICOS**

GEISON JADER MELLO

Tese apresentada ao Programa de Pós-Graduação em Física Ambiental da Universidade Federal de Mato Grosso, como parte dos requisitos para obtenção do título de Doutor em Física Ambiental.

Orientador: Prof. Dr. Marcelo Sacardi Biudes

**Cuiabá, MT
Dezembro de 2013**

Dados Internacionais de Catalogação na Fonte.

M527p Mello, Geison Jader.
Previsão Micrometeorológica no Pantanal Mato-Grossense pela Teoria de Sistemas Dinâmicos / Geison Jader Mello. -- 2013
xix, 125 f. : il. color. ; 30 cm.

Orientador: Marcelo Sacardi Biudes.
Tese (doutorado) - Universidade Federal de Mato Grosso, Instituto de Física, Programa de Pós-Graduação em Física Ambiental, Cuiabá, 2013.
Inclui bibliografia.

1. dinâmica não linear. 2. reconstrução do espaço de fase. 3. predição não linear. I. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Permitida a reprodução parcial ou total, desde que citada a fonte.

UNIVERSIDADE FEDERAL DE MATO GROSSO
INSTITUTO DE FÍSICA
Programa de Pós-Graduação em Física Ambiental

FOLHA DE APROVAÇÃO

**TÍTULO: PREVISÃO MICROMETEOROLÓGICA NO PANTANAL
MATO-GROSSENSE PELA TEORIA DE SISTEMAS
DINÂMICOS**

AUTOR: GEISON JADER MELLO

Tese de Doutorado defendida e aprovada em 06 de dezembro de 2013, pela comissão julgadora:


Prof. Dr. Marcelo Sacardi Biudes
Orientador
Instituto de Física - UFMT


Prof. Dr. Marcelo Paes de Barros
Examinador Interno
Instituto de Física - UFMT


Prof. Dr. Carlo Ralph De Musis
Examinador Interno
Universidade de Cuiabá - UNIC


Prof. Dr. Marcelo Peres Rocha
Examinador Externo
Universidade de Brasília - UNB


Prof. Dr. Bernardo Barbosa da Silva
Examinador Externo
Universidade Federal de Campina Grande - UFCG

DEDICATÓRIA

À Deus pela vida, à minha esposa Regina Célia, aos meus filhos Vitor Mello e Lorenzo Mello pelo amor e compreensão, e aos meus pais Jade Mello e Zeni Mello pelo amor, oportunidades e sacrifícios.

AGRADECIMENTOS

Agradeço especialmente ao meu orientador, Prof. Dr. Marcelo Sacardi Biudes, pelo apoio, amizade, companheirismo e conhecimento depositado em mim na orientação deste trabalho, se apresentando sempre presente e acessível em todos os momentos. Acima de tudo, um grande amigo.

Ao Prof. Dr. José de Souza Nogueira, pela motivação, por apontar a direção correta e por compartilhar de suas experiências.

Ao prof. MSc. Raphael de Souza Rosa Gomes, companheiro na aplicação de métodos computacionais na análise e modelagem de séries temporais não lineares.

Ao Magnífico Reitor do IFMT Prof. José Bispo Barbosa pelo apoio e solicitude.

Aos professores do IFMT - SVC - NAJ, Diretor de Núcleo Dr. Leandro Carbo, coordenador MSc. Marcos Vinicius Vilela, MSc. Roberta Lima Moretti, MSc. Dayse Oliveira, MSc. Ronaldo Eustáquio Feitoza Senra, Gláucia Mara de Barros (Pró-reitora de Administração e Planejamento) e Dr. Degmar Francisco dos Anjos (Pró-reitor de Desenvolvimento Institucional) pelo companheirismo e amizade.

Ao Dr. Norbert Marwan, do Potsdam Institute for Climate Impact Research - PIK pela gentileza na disponibilização da caixa de ferramentas TOCSY - Toolbox for Complex Systems for Matlab®.

Ao Dr. Rainer Hegger, Dr. Holger Kantz e Dr. Thomas Schreiber pela disponibilização do pacote de software TISEAN – Nonlinear Time Series Analysis.

Aos meus bons amigos da Pós-Graduação em Física Ambiental, pelo auxílio nesta caminhada: Dr. Geraldo Aparecido Rodrigues Neves, MSc. Erondina Azevedo de Lima, Dr. Flair José Carrilho Sobrinho, MSc. Paulo Henrique Zanella de Arruda,

MSc. Cristiano Rocha Cunha, MSc. Sérgio Wagner Gripp da Silveira e Dr^a. Nadja Gomes Machado.

Aos professores Dr. Carlo Ralf de Muis, Dr^a. Marta Cristina de Jesus Albuquerque Nogueira, Dr. Geraldo Lúcio Diniz, Dr^a. Luciana Sanches e Dr. Denilton Carlos Gaio, pelos preciosos conhecimentos compartilhados ao longo do curso de doutorado.

Aos funcionários da Pós-Graduação em Física Ambiental: MSc. Soilce Carrilho e Cesário Gonçalves de Queiroz Filho pela gentileza e polidez em todos os momentos.

Aos professores Dr. Sergio Roberto de Paulo e a Dra. Iramaia Jorge Cabral de Paulo, precursores nos estudos sobre a Teoria da Complexidade aplicada ao meio ambiente neste programa de Pós-Graduação aos quais atribuímos com muito respeito e admiração o êxito deste trabalho, devido às diretrizes apontadas desde a graduação em Ciências Naturais, também no mestrado e no início de doutorado.

À CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pelo apoio financeiro através da bolsa de mestrado e doutorado.

À FAPEMAT através do Programa de Apoio a Núcleos de Excelência (PRONEX) pelo apoio financeiro ao projeto de pesquisa processo n. 823971/2009.

A todas as pessoas que direta ou indiretamente contribuíram para a realização deste trabalho.

EPÍGRAFE

"não jogue fora o bebê junto com a água do banho"

("don't throw the baby out with the bath water", de Thomas Murmer, em Narrenbeschwörung, 1512; parafraseado por Dr. Sergio Roberto de Paulo)

SUMÁRIO

LISTA DE FIGURAS.....	X
LISTA DE TABELAS.....	XV
LISTA DE ABREVIATURAS E SÍMBOLOS	XVI
RESUMO.....	XVIII
ABSTRACT.....	XIX
1. INTRODUÇÃO	1
2. FUNDAMENTAÇÃO TEÓRICA.....	4
2.1. MICROMETEOROLOGIA.....	5
2.1.1. <i>Pantanal Norte Mato-Grossense</i>	5
2.2. TESTE DE NÃO LINEARIDADE.....	9
2.2.1. <i>Função de Autocorrelação $ACF(\tau)$</i>	10
2.2.2. <i>Transformada Rápida de Fourier FFT</i>	12
2.2.3. <i>Teste Surrogate SUR</i>	13
2.3. RECONSTRUÇÃO DO ESPAÇO DE FASE	14
2.3.1. <i>Escolha do Tempo de Defasagem τ</i>	19
2.3.2. <i>Escolha da Dimensão de Imersão m</i>	21
2.4. ANÁLISE DE SÉRIES TEMPORAIS NÃO LINEARES	25
2.4.1. <i>Gráficos de Recorrência RP</i>	26
2.4.2. <i>Análise Quantitativa de Recorrência</i>	29
2.4.3. <i>Expoentes de Lyapunov λ</i>	33
2.4.4. <i>Dimensão de Correlação $D2$</i>	35
2.5. PREDIÇÃO NÃO LINEAR E VERIFICAÇÃO DO MODELO	37
2.5.1. <i>Tempo Máximo de Previsão Confiável ξ</i>	37
2.5.2. <i>Predição Não Linear Simples</i>	38
3. MATERIAL E MÉTODOS	41
3.1. LOCALIZAÇÃO E INSTRUMENTOS	41
3.2. ANÁLISE E PREDIÇÃO DE SÉRIES TEMPORAIS NÃO LINEARES	42
3.2.1. <i>Medidas de Erro de Predição</i>	43

4. RESULTADOS E DISCUSSÃO	45
4.1. DESCRIÇÃO MICROCLIMÁTICA.....	45
4.2. TESTE DE NÃO LINEARIDADE.....	48
4.3. RECONSTRUÇÃO DO ESPAÇO DE FASE	49
4.4. ANÁLISE DAS SÉRIES TEMPORAIS NÃO LINEARES.....	54
4.4.1. Gráficos de Recorrência <i>RP</i>	54
4.4.2. Análise de <i>Quantificação de Recorrência – RQA</i>	60
4.4.3. Expoentes de Lyapunov λ	65
4.4.4. Dimensão de Correlação D2	67
4.5. PREDIÇÃO NÃO LINEAR E VERIFICAÇÃO DO MODELO	70
4.5.1. Tempo Máximo de Previsão Confiável	70
4.5.2. Predição Não Linear Simples e Medidas de Erro de Predição	71
5. CONCLUSÃO	93
6. REFERÊNCIAS.....	95

LISTA DE FIGURAS

- Figura 1.** (a) Função de autocorrelação de uma série temporal periódica e (b) de uma série de dados aleatórios (MELLO et al., 2013b (no prelo)). 11
- Figura 2.** Série temporal de temperatura (superior) e seu respectivo surrogate (inferior) (MELLO et al., 2012b). 14
- Figura 3.** (a) O espaço de fase bidimensional de um pêndulo, (b) trajetória do pêndulo no espaço de fase, e (c) trajetória no espaço de fase de um pêndulo com atrito (adaptado de Capra, 2006). 15
- Figura 4.** (A) solução numérica do sistema de equações de Lorenz (1963) para $x(t)$, $y(t)$ e $z(t)$ e (B) representação do espaço de fase tridimensional do atrator estranho de Lorenz (parâmetros de controle $\rho = 25$, $\sigma = 10$, $\beta = 8/3$). 17
- Figura 5.** Reconstrução tridimensional dos atratores das variáveis teóricas 18
- Figura 6.** Efeito da defasagem temporal τ na reconstrução do atrator de Lorenz (1963) à partir da série x em um espaço de imersão $m=3$: (a) defasagem muito pequena, (b) uma defasagem muito grande e (c) para uma defasagem adequada (MELLO et al., 2013b). 19
- Figura 7.** (a) Informação Mútua da série *Seno* com primeiro mínimo local igual a 24, (b) Informação Mútua da série *Chaos X* de Lorenz (1963) com primeiro mínimo local igual a 60, e (c) Informação Mútua da série *Random* com primeiro mínimo local igual a 1. 21
- Figura 8.** (a) $\ln C(r)$ vs $\ln r$ para valores crescentes de m para o atrator reconstruído a partir da série x de Lorenz, (b) $\ln C(r)$ vs $\ln r$ para uma série de dados aleatórios; e (c) saturação da dimensão de correlação versus dimensão de imersão m para o atrator reconstruído a partir da série x de Lorenz (1963) com $D_c \approx 2,05 \pm 0,01$ e $m = 3$ (●) e para a série aleatória com dimensão m infinita (o). 23
- Figura 9.** Esquema representativo do método FNN para (a) duas dimensões de imersão m com falsas trajetórias interceptadas (falsos vizinhos) e para (b) com três dimensões de imersão m sem falsas interceptações 24
- Figura 10.** Fração de falsos vizinhos mais próximos FNN, em função da dimensão de imersão m das séries temporais (a) Seno, (b) Chaos e (c) Random. 25
- Figura 11.** Onde (a) é segmento da trajetória no espaço de fase do sistema de Lorenz (parâmetros de controle $r = 28$, $\sigma = 10$, $b = 03/08$; Lorenz, 1963), usando as três componentes x , y e z ; e (b) correspondente a sua parcela de recorrência. Um ponto da

trajetória de j dentro da vizinhança (círculo cinza em (A)) de um determinado ponto no i é considerado como um ponto de recorrência (ponto preto sobre a trajetória de (A)). Este é marcado com um ponto preto no RP no local (i, j) . Um ponto fora da vizinhança (pequeno círculo de (A)) provoca um ponto branco no RP. O raio da vizinhança para o RP é $\varepsilon = 5$ (Disponível em <http://www.recurrence-plot.tk/glance.php> acesso em 12/2011)..... 27

Figura 12. Gráficos de Recorrência de (a) movimento periódico de uma frequência, (b) atrator estranho de Rossler (parâmetros $a=b=0.2$ e $c=5.7$) e (c) ruído branco (MARWAN et al., 2007)..... 27

Figura 13. Análise de Quantificação de Recorrência *RQA* da variável teórica *seno*. 32

Figura 14. Análise de Quantificação de Recorrência *RQA* da variável teórica *chaos*. 32

Figura 15. Análise de Quantificação de Recorrência *RQA* da variável teórica *random*. 33

Figura 16. Estimativa do maior expoente de Lyapunov para a (a) reconstrução do atrator da série Seno sem divergência exponencial das trajetórias, (b) reconstrução do atrator associado a série Chaos [Lorenz (1963) a partir da variável x , $\tau = 60$, parâmetros de controle $\rho = 25$, $\sigma = 10$, $\beta = 8/3$, passo de 0,01 segundo com m crescente de 1 a 3, obtendo $\lambda_{max} = 0,0092$] e (c) reconstrução do atrator da série Random também não apresentando divergência exponencial das trajetórias. 34

Figura 17. A esquerda $\ln C(r)$ vs $\ln r$ para valores crescentes de m , e a direita saturação da dimensão de correlação $D2$ versus dimensão de imersão m para o atrator reconstruído a partir das variáveis teóricas..... 36

Figura 18. Esquema da Predição Não Linear Simples. Reconstrói-se o atrator a partir de uma série temporal medida, e busca-se a média do futuro dos estados vizinhos. Desses estados futuros é extraída a série temporal predita (figura adaptada de BASHARAT & SHAH, 2009)..... 39

Figura 19. Mapa do Brasil, com destaque para o Pantanal Brasileiro, localização da área de vegetação monodominante de Cambará na RPPN SESC e da torre micrometeorológica..... 42

Figura 20. Média mensal do saldo de radiação (R_n), da temperatura do ar (T) e da umidade relativa (R_h)..... 47

Figura 21. Informação Mutua MI para a escolha do tempo de defasagem τ 50

Figura 22. Falsos Vizinhos Próximos *FNN* para a escolha da melhor dimensão de imersão m 50

Figura 23. Reconstrução tridimensional dos atratores das variáveis microclimáticas.	50
Figura 24. Reconstrução tridimensional dos atratores associados às variáveis microclimáticas com ênfase na sazonalidade utilizando janeiro para períodos chuvosos e julho para períodos secos.....	52
Figura 25. Gráficos de Recorrência RP da variável microclimática Rn	56
Figura 26. Gráficos de Recorrência RP da variável microclimática T	58
Figura 27. Gráficos de Recorrência RP da variável microclimática Rh	60
Figura 28. Análise de Quantificação de Recorrência RQA da variável microclimática Rn	63
Figura 29. Análise de Quantificação de Recorrência RQA da variável microclimática T	64
Figura 30. Análise de Quantificação de Recorrência RQA da variável microclimática Rh	64
Figura 31. Maior Expoentes de Lyapunov λ das variáveis microclimáticas global (série temporal completa).....	66
Figura 32. Maior Expoentes de Lyapunov λ das variáveis microclimáticas local (séries mensais).....	66
Figura 33. A esquerda $\ln C(r)$ vs $\ln r$ para valores crescentes de m , e a direita saturação da dimensão de correlação $D2$ versus dimensão de imersão m para o atrator reconstruído a partir das variáveis micrometeorológicas.	68
Figura 34. Dimensão de Correlação $D2$ (local) das variáveis microclimáticas (séries mensais).....	69
Figura 35. (a) Série temporal de Rn medida e predita, janeiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	73
Figura 36. (a) Série temporal de Rn medida e predita, fevereiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	73
Figura 37. (a) Série temporal de Rn medida e predita, março de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	74
Figura 38. (a) Série temporal de Rn medida e predita, abril de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	74
Figura 39. (a) Série temporal de Rn medida e predita, maio de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	75

Figura 40. (a) Série temporal de Rn medida e predita, junho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	75
Figura 41. (a) Série temporal de Rn medida e predita, julho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	76
Figura 42. (a) Série temporal de Rn medida e predita, agosto de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	76
Figura 43. (a) Série temporal de Rn medida e predita, setembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	77
Figura 44. (a) Série temporal de Rn medida e predita, outubro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	77
Figura 45. (a) Série temporal de Rn medida e predita, novembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	78
Figura 46. (a) Série temporal de Rn medida e predita, dezembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	78
Figura 47. (a) Série temporal de T medida e predita, janeiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	79
Figura 48. (a) Série temporal de T medida e predita, fevereiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	79
Figura 49. (a) Série temporal de T medida e predita, março de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	80
Figura 50. (a) Série temporal de T medida e predita, abril de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	80
Figura 51. (a) Série temporal de T medida e predita, maio de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	81
Figura 52. (a) Série temporal de T medida e predita, junho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	81
Figura 53. (a) Série temporal de T medida e predita, julho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	82
Figura 54. (a) Série temporal de T medida e predita, agosto de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	82
Figura 55. (a) Série temporal de T medida e predita, setembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	83

Figura 56. (a) Série temporal de T medida e predita, outubro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	83
Figura 57. (a) Série temporal de T medida e predita, novembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	84
Figura 58. (a) Série temporal de T medida e predita, dezembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	84
Figura 59. (a) Série temporal de Rh medida e predita, janeiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	85
Figura 60. (a) Série temporal de Rh medida e predita, fevereiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	85
Figura 61. (a) Série temporal de Rh medida e predita, março de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	86
Figura 62. (a) Série temporal de Rh medida e predita, abril de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	86
Figura 63. (a) Série temporal de Rh medida e predita, maio de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	87
Figura 64. (a) Série temporal de Rh medida e predita, junho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	87
Figura 65. (a) Série temporal de Rh medida e predita, julho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	88
Figura 66. (a) Série temporal de Rh medida e predita, agosto de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	88
Figura 67. (a) Série temporal de Rh medida e predita, setembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	89
Figura 68. (a) Série temporal de Rh medida e predita, outubro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	89
Figura 69. (a) Série temporal de Rh medida e predita, novembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	90
Figura 70. (a) Série temporal de Rh medida e predita, dezembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local}	90

LISTA DE TABELAS

Tabela 1. Média mensal e estacional e desvio padrão mensal e estacional do saldo de radiação (Rn), da temperatura do ar (T) e da umidade relativa (Rh).....	46
Tabela 2. Parâmetros para a construção das séries Surrogate.....	48
Tabela 3. Parâmetro para a reconstrução do espaço de fase.	49
Tabela 4. Valores de Dc de Temperatura na literatura.....	69
Tabela 5. Tempo Máximo de Previsão Confiável ξ (Tempo de Lyapunov).....	70
Tabela 6. Média e desvio padrão das Medidas de Erro de Predição das séries temporais micrometeorológicas quanto ao parâmetro ξ e a sazonalidade.	91

LISTA DE ABREVIATURAS E SÍMBOLOS

η_n	Ruído de medição
D_2	Dimensão de correlação
S_n	Série temporal genérica
λ_{max}	Maior Expoente de Lyapunov
$ACF(\tau)$	Função de autocorrelação
DET	Média de quantificação de recorrência
DIV	Média de quantificação de recorrência: divergência
$ENTR$	Média de quantificação de recorrência: Entropia
FFT	Transformada rápida de Fourier
FNN	Falsos vizinhos próximos
L	Medida de quantificação de recorrência: razão de recorrência
LAM	Média de quantificação de recorrência: Laminaridade
MI	Informação mútua
N	Comprimento da série temporal
$P(\cdot)$	Histograma
$R(\varepsilon)$	Matriz de recorrência de uma trajetória no espaço de fase, usando uma vizinhança de raio ε
Rh	Série temporal de umidade relativa
RP	Gráfico de recorrência
RQA	Análise de quantificação de recorrência
RR	Medida de quantificação de recorrência: razão de recorrência (porcentagem de recorrência)
Rn	Série temporal de balanço de radiação
SUR	Teste surrogate
T	Série Temporal de Temperatura
TAR	Limiar autoregressivo
TT	Média de quantificação de recorrência: Tempo de Aprisionamento
i, j, k	Índices

l	Comprimento de uma linha diagonal de um Gráfico de Recorrência
m	Dimensão de imersão
p	Probabilidade
<i>random</i>	Série de dados aleatórios
v	Comprimento de uma linha vertical de um Gráfico de Recorrência
$\theta(\cdot)$	Função de Heaviside $\theta(\cdot) = \{1 x > 0; 0 x \leq 0\}$
ε	Raio da vizinhança de um ponto (limiar de sondagem)
λ	Expoente de Lyapunov
ξ	Tempo Máximo de Previsão Confiável
σ	Desvio padrão
τ	Tempo de defasagem

RESUMO

MELLO, G. J. **Previsão micrometeorológica no Pantanal Mato-Grossense pela teoria de sistemas dinâmicos**. Cuiabá, 2013, 125f. Tese (Doutorado em Física Ambiental) - Instituto de Física, Universidade Federal de Mato Grosso.

As variáveis micrometeorológicas medidas em ecossistemas possuem comportamento não linear e representam a dinâmica dos processos físicos e biológicos que ocorrem entre a superfície vegetada e a atmosfera. Sendo assim, o objetivo deste trabalho foi entender o comportamento micrometeorológico de uma floresta sazonalmente inundada no Pantanal Mato-grossense, a partir da análise séries temporais de saldo de radiação, temperatura e umidade do ar (com dados de 15 em 15 minutos), medidos acima do dossel, e fazer previsões utilizando a teoria dos sistemas dinâmicos. Inicialmente foram aplicados testes de não linearidade que justificam a abordagem. Em seguida, o espaço de fase contendo o conjunto atrator associado a cada série temporal é reconstruído por meio de defasagem temporal e dimensão de imersão respectivamente pelos métodos da Informação Mútua e Falsos Vizinhos Próximos. Visando extrair informações para a previsão, é feita a caracterização das variáveis segundo a análise de séries temporais não lineares, em termos qualitativos por Gráficos de Recorrência apresentando textura sazonal não linear, quantificado pela Análise Quantitativa de Recorrência. Também foram avaliadas a dinâmica e a geometria das séries, respectivamente pelo maior expoente de Lyapunov pela dimensão de correlação. Por fim, é aplicado o método de Predição Não Linear Simples que utiliza uma série medida para estimar uma série prevista, que é verificada em termos de correlação, exatidão e erros dentro do tempo estabelecido pelo parâmetro de previsão confiável. Os resultados evidenciam a existência de atratores estranhos de baixa dimensão fractal e sensíveis à sazonalidade, e que o método de predição não linear simples captura a dinâmica geral das séries temporais micrometeorológicas medidas.

Palavras-chave: dinâmica não linear, reconstrução do espaço de fase, predição não linear.

ABSTRACT

MELLO, G. J. **Forecast micrometeorological the Pantanal of Mato Grosso by dynamical systems theory.** Cuiabá, 2013, 125f. Thesis (Doctorate. in Environmental Physics) - Institute of Physics, Federal University of Mato Grosso.

Micrometeorological variables measured in ecosystems possess nonlinear behavior and represent the dynamics of the physical and biological processes that occur between the vegetated surface and atmosphere. Thus, the aim of this study was to understand the behavior of a micrometeorological seasonally flooded forest in Pantanal, from the time series analysis of the net radiation, temperature and humidity (with data from 15 to 15 minutes), measured above the canopy, and make predictions using the theory of dynamical systems. In order to justify the approach, we performed tests of nonlinearity. Then the phase space containing the whole attractor associated to each time series is reconstructed by time delay and dimension of immersion respectively by the methods of Mutual Information and False Neighbors Next. Aiming to extract information for the prediction, we characterize the variables according to the analysis of nonlinear time series, the quality of charts presenting recurrence texture seasonal nonlinear quantified by Quantitative Analysis of Recurrence. Also evaluated are the dynamics and geometry of the series, respectively the largest Lyapunov exponent for the correlation dimension. Finally the method is applied in simple non-linear prediction that uses a series measurement to estimate an expected range. It is verified the correlation, accuracy and errors within the time set by parameter reliable forecast. The results show the existence of strange attractors of low fractal dimension and sensitive to seasonality, and that the prediction method captures the simple non-linear dynamics of the overall series micrometeorological measurements.

Keywords: nonlinear dynamics, state space reconstruction, nonlinear prediction.

1. INTRODUÇÃO

O Pantanal ocupa o lugar de maior planície tropical de inundação sazonal do planeta, abrigando biodiversidade desproporcionalmente alta e distinguindo-se por fauna e flora peculiar. Este status permite desempenhar papel muito importante na estabilidade dinâmica do clima regional.

Pesquisas recentes encontraram indícios de alteração no ciclo hidrológico do norte do Pantanal. Isto foi caracterizado pelo aumento dos picos de precipitação máxima, sugerindo que esse ciclo está sendo afetado pelas mudanças climáticas. Há ainda uma rápida mudança na vegetação em campos sazonalmente inundados que também tem sido considerado um efeito de mudanças climáticas ocorridas em ciclos plurianuais.

O desmatamento é o maior estigma da atividade antrópica inserida na dinâmica da ocupação do espaço do Pantanal. Com o objetivo de ampliar as áreas destinadas à agricultura e à pecuária, o desmatamento exerce impactos negativos junto ao ecossistema local causando desequilíbrio sistêmico, a exemplo do que ocorre na Reserva Particular do Patrimônio Natural (RPPN) SESC Pantanal Matogrossense que vem sofrendo invasão de uma vegetação mono-dominante chamada Cambará (*Vochysia divergens Pohl*).

Sabe-se que com a troca da cobertura vegetal original por áreas de pastagens e cultivos, o fluxo de vapor de água para a atmosfera é alterado, bem como a

refletividade do solo, afetando diretamente o saldo de radiação, entre outros efeitos. Mas ainda não se compreendem claramente como estas alterações regionais no uso do solo podem afetar o ciclo hidrológico e o regime de chuvas na região. Um dos motivos é a falta de séries históricas de dados micrometeorológicos medido *in situ* para detectar e monitorar estas possíveis mudanças no clima regional. Desta forma é de suma importância compreender e fazer previsões da dinâmica de variáveis micrometeorológicas como o saldo de radiação, a temperatura e a umidade relativa do ar, e as suas relações diante do cenário das mudanças climáticas locais e globais a curto e longo prazos.

Sabe-se que as séries temporais medidas nesses sistemas microclimáticos não são nem aleatórias e nem seguem um padrão linear, de forma que é coerente afirmar que os dados possuem mais estruturas do que os métodos tradicionais e as ferramentas lineares são capazes de capturar, especialmente porque a não linearidade é inerente aos ecossistemas. De fato, a descrição micrometeorológica de ecossistemas, como florestas tropicais sazonalmente inundadas, visto a sua não linearidade, o número e a variedade de subsistemas em interação, assim como os efeitos antropogênicos é um problema expressivo.

Os ecossistemas são sistemas abertos, dinâmicos e complexos e o seu estudo necessita de ferramentas que sejam capazes de capturar a dinâmica das séries temporais medidas na floresta e também que possam contribuir com projeções futuras. Avanços nesta direção têm sido relatados com a aplicação de ferramentas adequadas para se compreender e prever a dinâmica das séries temporais medidas em florestas tropicais.

Destacam-se as pesquisas que analisam a possível natureza não linear dos dados ambientais, contribuindo para o entendimento e modelagem da interação biosfera-atmosfera. Embasado na teoria dos sistemas dinâmicos, várias pesquisas envolvendo séries temporais de diferentes variáveis ambientais mencionam a possível existência de atratores climáticos de baixa dimensão fractal e indicam o número mínimo de variáveis presentes na evolução da dinâmica do sistema.

Nesta perspectiva o objetivo geral deste trabalho foi entender o comportamento micrometeorológico do Pantanal a partir da análise das variáveis micrometeorológicas saldo de radiação, temperatura e umidade relativa do ar

medidas a cada 15 minutos buscando prever este comportamento por meio da teoria de sistemas dinâmicos.

Para tanto, foram definidos os seguintes objetivos específicos: analisar as séries temporais micrometeorológicas, reconstruir os atratores associados a essas séries e analisar as suas recorrências qualitativa e quantitativamente, estimar a divergência exponencial e a dimensão fractal das trajetórias desses atratores, estimar o tempo máximo de previsão confiável e fazer previsões utilizando o método de previsão não linear simples.

2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo foram apresentados os aspectos teóricos que delimitam a análise e previsão de séries temporais não lineares segundo a teoria dos sistemas dinâmicos. Na Seção 2.1 foi conceituada a micrometeorologia com aprofundamento da micrometeorologia do Pantanal Norte de Mato Grosso. Em seguida, foram apresentados na Seção 2.2 métodos que possibilitam classificar as séries temporais como não lineares em termos de limitações e suficiências. Na Seção 2.3 foram apresentadas as metodologias de reconstrução do espaço de fase a partir de uma série temporal em termos de tempo de atraso temporal τ e dimensão de imersão m do conjunto atrator. Na Seção 2.4 foram apresentados os métodos de análise não linear de séries temporais baseados no espaço de fase, em termos de resultados qualitativos e quantitativos, e de análise da dinâmica e geometria do conjunto atrator que fundamentam uma previsão confiável. Por fim, aborda-se na Seção 2.5 o tempo de previsão confiável a partir da análise do atrator e o método de predição não linear simples.

2.1. MICROMETEOROLOGIA

Como um ramo da meteorologia, a micrometeorologia concentra-se em processos que afetam diretamente os ambientes até mil metros de altura (a chamada camada limite atmosférica) e sobre regiões com apenas alguns quilômetros de extensão, com escala temporal inferior a uma hora e espacial inferior a 1 km (ARYA, 2001). Esta área de estudo ocupa-se principalmente dos processos de transporte e de fluxos entre a atmosfera e a superfície subjacente (WALLACE & HOBBS, 2006). Em geral ocupa-se dos fenômenos de turbulência atmosférica, dispersão atmosférica de partículas e gases, troca de energia e massa na interação solo-planta-atmosfera, balanço de energia, evapotranspiração (REICHARDT & TIMM, 2008), e também análise e modelagem da dinâmica desses fenômenos, tal qual o saldo de radiação, a temperatura e a umidade relativa (ARYA, 2001; WALLACE & HOBBS, 2006; FOKEN, 2008).

2.1.1. *Pantanal Norte Mato-Grossense*

O Pantanal é um bioma localizado na Bacia do Alto Rio Paraguai, na Região Centro-Oeste, abrangendo parte dos estados do Mato Grosso e Mato Grosso do Sul com 138.183 km² (VILA DA SILVA & ABDON, 1998), e exceto por uma faixa que adentra o Paraguai e a Bolívia, o Pantanal é quase todo restrito ao território brasileiro (IBGE, 2004). Denominado Planície do Pantanal é mais conhecida como Pantanal Mato-Grossense, suas origens estão relacionadas aos movimentos de compensação ocorridos na época do soerguimento da Cordilheira dos Andes, representando a parte mais rebaixada e mais plana da bacia hidrográfica e constituindo-se na maior planície inundável do mundo (BRASIL & ALVARENGA, 1989).

Situado entre 80 e 150 m de altitude, o Pantanal apresenta declividade quase nula e possui apenas um vertedouro que é a calha do rio Paraguai no seu prolongamento para a confluência com o rio Paraná. Quanto ao solo, o Pantanal possui um terreno predominantemente pouco permeável para o alagamento (SOUZA & LANI, 2004). As inundações que anualmente ocorrem nessa planície, por atingirem grande extensão, serem de longa duração e por imprimirem modificações

de vulto no meio físico, na vida silvestre e no cotidiano das populações locais, constituem o fator determinante da existência desse ecossistema (SOUZA & CUNHA, 2004). Estas características fazem com que, a cada ano, após alguns meses de chuvas, a Planície do Pantanal se transforme numa imensa área alagada, com grande parte dos biótopos terrestres passando para biótopos aquáticos (IBGE, 2004).

Nesta planície estão reunidos representantes de parte significativa da fauna brasileira, que durante o período de inundação, se deslocam para as áreas altas circunjacentes, principalmente os mamíferos e as aves, ou se refugiam nas áreas não alagadas, de onde só retornam quando a inundação termina. Ao término do período das cheias inicia-se o processo de retorno de plantas e animais em grandes bandos na busca por recursos proporcionados pela enchente (IBGE, 2004; SOUZA & CUNHA, 2004).

Em relação à ocupação do espaço, modificação da paisagem e uso do solo, o contexto regional foi composto de uma intensa ocupação humana ao longo dos últimos 30 anos sem uma política embasada em estudos científicos sobre impactos antrópicos, implicando em desflorestamento motivado pela indústria madeireira e/ou para dar lugar ao agronegócio (PICOLI, 2006).

Somam-se aos principais fatores de migrações para a região os incentivos públicos para ocupação do Cerrado e Amazônia, uma diversidade de recursos naturais presentes no Centro-Oeste e Norte, o rápido desenvolvimento econômico, o clima com estações chuvosas e secas bem definidas e terras agricultáveis e baratas se comparadas com outras regiões do país (PICOLI, 2011). Isto fez do estado de Mato Grosso o maior produtor de cereais, leguminosas e oleaginosas, respondendo por aproximadamente 25% da sua produção nacional (IBGE, 2013a), e por 27% do abate de bovinos do país juntamente com uma agroindústria em pleno crescimento (IBGE, 2013b).

Neste período de ocupação, as superfícies que circundam o Pantanal tiveram grande parte da cobertura vegetal original substituída por lavouras e pastagens, num processo que tende a se acelerar e que está repercutindo na planície com assoreamento dos rios e das superfícies mais rebaixadas (SALATI et al., 2006). Além disto, a região passou a ter os seus recursos minerais (ouro, diamante, ferro,

manglês) explorados com maior intensidade, geralmente com poucos cuidados em relação à conservação ambiental (SALATI et al., 2006).

A atividade humana é de fato a causa dos maiores impactos no Pantanal, efetivado através de queimadas e emissão de gases, aumento das médias da temperatura e diminuição da umidade do ar (NOBRE et al., 1996; McCLAIN, 2002; COSTA & PIRES, 2010; LEWIS et al., 2011, LAPOLA et al, 2011), assim como o ciclo hidrológico também tem se apresentado irregular com chuvas mais intensas em períodos mais curtos, picos de 400 a 500 mm de precipitação em apenas um mês em uma região com média anual em torno de 1400 mm (HASENACK et al., 2003; VIDAL, 2009).

Os possíveis cenários das mudanças climáticas com eventos extremos tais como prolongamento das secas, intensificação das enchentes e elevação das médias das temperaturas em alguns graus, indicam que as regiões de baixa latitude podem ser as mais impactadas em relação à produção agrícola, diminuindo a oferta de alimentos e contribuindo para a queda do Produto Interno Bruto (PIB), considerando-se a importância local no setor da agricultura (MOTTA et al., 2011). Recentemente, pesquisadores encontraram indícios de alteração no ciclo hidrológico do norte do Pantanal, que foi caracterizado pelo aumento dos picos de precipitação máxima, e sugerem que o ciclo está sendo afetado pelas mudanças climáticas (DINIZ et al., 2008). Há ainda uma rápida mudança na vegetação em campos sazonalmente inundados que também tem sido considerado um efeito de mudanças climáticas ocorridas em ciclos plurianuais (ARIEIRA & NUNES DA CUNHA, 2006).

Fazem-se necessários estudos para compreensão e modelagem desses ecossistemas no sentido de se tornarem vetores de políticas públicas ambientais e racionalização para sustentabilidade de recursos naturais (ASSAD & PINTO, 2008).

A Universidade Federal de Mato Grosso foi criada a mais de 35 anos e tem mantido como uma de suas prioridades a geração de conhecimentos sobre o Estado de Mato Grosso e sobre os grandes ecossistemas que o compõem, tais como, o Pantanal, o Cerrado e a Floresta Tropical Úmida. Nesta perspectiva, desde 2002 o Programa de Pós-Graduação em Física Ambiental produz pesquisas científicas que buscam ampliar o entendimento sobre o funcionamento dos ecossistemas da região e integrar as dimensões sociais e econômicas às pesquisas ambientais de ponta. Uma

das metodologias adotadas é a instalação de torres micrometeorológica com equipamentos dispostos ao longo de seu perfil para medir em forma de séries temporais experimentais os aspectos com relevância biológica. Essas séries temporais, que por sinal fazem parte do objeto de estudo deste trabalho, propiciam estudar o comportamento acoplado da atmosfera com a vegetação, os fluxos de *momentum* de calor latente e sensível, a produtividade primária e o ciclo do carbono, o balanço de energia, o saldo de radiação, a temperatura, a umidade relativa, a fotossíntese, os aerossóis e gases traços na atmosfera, aspectos relacionados ao solo, assim como a estabilidade ou não diante de perturbações antropogênicas, que são considerados em detalhes nas descrições e modelagem (VOURLITIS et al., 2002; PRIANTE FILHO et al., 2004; VOURLITIS et al., 2008; BIUDES et al., 2009; BIUDES et al., 2012; BIUDES et al., 2013).

A questão da descrição de florestas, tendo como exemplo as florestas inundadas é um problema brasileiro extremamente significativo (GOMES & VARRIALE, 2004). A busca da compreensão do comportamento do ecossistema via fenômenos micrometeorológicos e as suas interações com a superfície terrestre envolve a teoria dos sistemas dinâmicos e depende dos fenômenos observados/descritos e a sua escala espaço-temporal (MELLO et al., 2011; MELLO et al., 2012a). A não linearidade está presente nas características fundamentais que determinam a dinâmica do comportamento de áreas alagadas, também na sua interação com a vizinhança terrestre, com a bacia hidrográfica a qual pertence, com a atmosfera assim como com os efeitos antropogênicos (GOMES & VARRIALE, 2004; MELLO et al., 2012b; MELLO et al., 2013a).

Dada a complexidade do sistema ambiental Pantanal, com o seu elevado número de variáveis em interação, a fundamentação teórica deste trabalho foi dirigida para uma teoria robusta adequada a esta aplicação: a teoria dos sistemas dinâmicos. Esta teoria está na vanguarda da investigação em ciências ambientais, a exemplo da física ambiental, biometeorologia e ciências atmosféricas (MILLÁN et al., 2010).

Contudo, antes da abordagem por teoria dos sistemas dinâmicos é fundamental que estas séries temporais microclimatológicas medidas em torres experimentais sejam testadas com respeito a sua não linearidade, justificando de

forma sólida a aplicação de tais ferramentas (MELLO et al., 2012b). Assim, na próxima Seção foi apresentada uma revisão sobre séries temporais lineares e não lineares com foco no teste de não linearidade em termos de eficácia e limitação.

2.2. TESTE DE NÃO LINEARIDADE

Uma série temporal pode ser entendida como uma sequência de medidas escalares de alguma quantidade que depende do estado do sistema e que é realizada em múltiplos de um tempo de amostragem fixo, sendo representada na forma:

$$S_n = S(x(n\Delta t)) + \eta_n \quad \text{Eq. 1}$$

Ou seja, o sistema é observado através de uma função de medição S juntamente com observações de algumas flutuações aleatórias η_n , chamado ruído de medição. Esta inevitável presença de ruído em séries temporais experimentais torna o seu estudo mais difícil podendo ocorrer interpretações incorretas dos resultados (KANTZ & SCHREIBER, 2004).

A análise dessas séries temporais compreende métodos que se destinam a extrair informações significativas necessárias para a descrição dos dados, com vistas à previsão dessas séries temporais, constituindo os modelos que utilizam os valores do passado para prever valores do futuro (MORETTIN & TOLOI, 2006).

Os métodos para a análise de séries temporais podem ser lineares e não lineares. Os métodos lineares são basicamente divididos em duas classes: os métodos no domínio da frequência, como o algoritmo de análise espectral conhecido como transformada rápida de Fourier (*FFT*), e os métodos de domínio de tempo, como método da função de autocorrelação $ACF(\tau)$ de um intervalo de tempo τ (KANTZ & SCHREIBER, 2004; SAVI, 2006).

Geralmente processos regulares, tais como periódicos ou quase-periódicos, podem ser identificados através de métodos lineares de análise de séries temporais experimentais (MORETTIN & TOLOI, 2006). Esses métodos lineares são importantes, mas não são suficientes para caracterizar a complexidade das séries temporais não lineares, necessitando serem complementados com métodos mais robustos (NICOLIS & PRIGOGINE, 1998).

Os métodos para a análise de séries temporais não lineares, basicamente conhecidos como métodos do espaço de fase ou medidas de complexidade, envolvem estimativas qualitativas e quantitativas de invariantes topológicos, a exemplo da dimensão de correlação D_2 e expoentes de Lyapunov λ_{max} , que são tratados na Seção 2.4. Estes métodos, menos sensíveis a ruídos, são amplamente utilizados para caracterizar séries temporais que apresentam indícios de comportamento não linear, tais como irregularidades, multiperiodicidade, autocorrelação tendendo a zero rapidamente e espectro de potência contínuo. Também se aplicam a séries temporais provenientes de sistemas dinâmicos naturais e/ou experimentais com pressupostos de que possuem a soma de componentes determinísticos e aleatórios (KANTZ & SCHREIBER, 2004; SAVI, 2006).

Na Seção 2.2.1 e 2.2.2 foram tratadas das aplicações e limitações dos métodos $ACF(\tau)$ e FFT , respectivamente, assim como na 2.2.3 do teste surrogate SUR (THEILER et al., 1992; PROVENZALE et al., 1992; THEILER et al., 1993) que propicia a distinção entre não linearidade e aleatoriedade de séries temporais.

2.2.1. Função de Autocorrelação $ACF(\tau)$

A função de autocorrelação $ACF(\tau)$ é dada por:

$$ACF(\tau) = \frac{1}{N - \tau} \sum_{n=1}^{N-\tau} \frac{((x) - \bar{x})((x + \tau) - \bar{x})}{\sigma^2} \quad \text{Eq. 2}$$

em que N é o número de dados da série, \bar{x} sua média, σ^2 é a sua variância, e τ ($\tau = \tau\Delta t$) a variação temporal.

A função de autocorrelação indica o quanto a dinâmica, ou seja, a série temporal é correlacionada com ela própria em dois instantes de tempo diferentes, a partir de uma defasagem temporal (Figura 1).

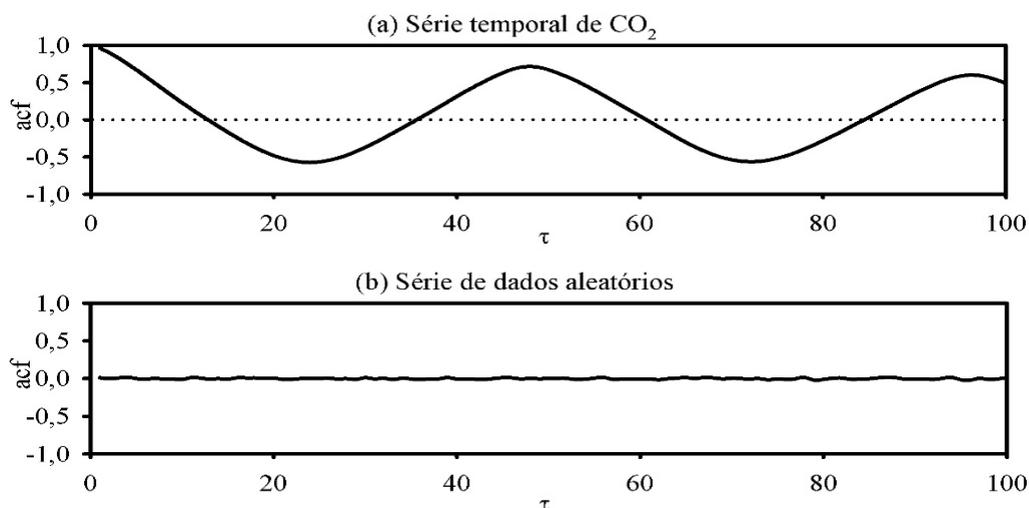


Figura 1. (a) Função de autocorrelação de uma série temporal periódica e (b) de uma série de dados aleatórios (MELLO et al., 2013b (no prelo)).

A sua aplicação parte da premissa que os dados vizinhos em uma série temporal são correlacionados, e desta forma, para extrair o máximo de informação desta série, estima-se o grau de correlação de uma variável em um dado instante consigo mesma à medida que o tempo (ou τ) passa, ou seja, a dependência entre o mesmo sinal defasado (KYOUNG et al., 2011).

Importante observar que o intervalo de tempo τ se refere a uma diferença temporal que é um múltiplo inteiro da resolução amostral da série temporal estudada, ou seja $\tau = \tau\Delta t$ (KANTZ & SCHREIBER, 2004).

Para séries periódicas e quase periódicas, a $ACF(\tau)$ permanece diferente de zero e é igualmente periódica quando o tempo (ou τ) tende ao infinito, pois o sinal volta a parecer consigo após um período; e para sistemas altamente não lineares $ACF(\tau)$ tende a zero quando o tempo (ou τ) tende ao infinito (CAMPANHARO et al., 2008).

Quando a $ACF(\tau)$ decai rapidamente com o τ , a dinâmica varia rapidamente com o tempo; o oposto também é verdadeiro, demonstrando que a $ACF(\tau)$ contém informação sobre a frequência do sinal (BAKER & GOLLUB, 1996). Em séries temporais não lineares, a $ACF(\tau)$ tende a zero quando τ tende ao infinito, e num sinal multi-periódico, com muitas frequências independentes e incomensuráveis, também se confunde com a da série não linear, comprometendo a caracterização do comportamento, com base neste método (ABARBANEL et al., 1993, BAKER & GOLLUB, 1996). Ou seja, o comportamento da $ACF(\tau)$, a qual diminui rapidamente

com o τ é necessário, mas não suficiente para caracterização de uma dinâmica de baixa dimensão da série temporal em estudo (CAMPANHARO et al., 2008; KYOUNG et al., 2011).

O uso da $ACF(\tau)$ volta a ser abordado no contexto da Seção 2.3.1 que trata da escolha do tempo de defasagem temporal ótimo para a reconstrução do atrator.

2.2.2. Transformada Rápida de Fourier *FFT*

A chamada de transformada rápida de Fourier *FFT* é um método tradicional de análise de séries temporais pertencente ao domínio da frequência que utiliza a ideia da decomposição de uma série temporal em uma soma de funções trigonométricas de senos e cossenos (KANTZ & SCHREIBER, 2004; SAVI, 2006). Este método foi criado por Jean Baptiste Joseph Fourier em 1822 enquanto se dedicava à resolução das equações diferenciais que regem a transferência de calor utilizando a técnica de séries de senos e cossenos (Série de Fourier) para resolver seus problemas (MORETTIN & TOLOI, 2006). Essa transformada é muito utilizada para análise de sinais experimentais, visto que séries temporais com evoluções diferentes apresentam diferentes espectros de potências. Assim, a *FFT* estabelece a relação entre uma série temporal em determinado intervalo de tempo e as suas frequências dominantes. A *FFT* para a série temporal S_n é definida pela equação (3).

$$\hat{S}_k = \frac{1}{\sqrt{N}} \sum_{n=1}^N S_n e^{2\pi i k n / N} \quad \text{Eq. 3}$$

em que as frequências são $f_k = \frac{k}{N\Delta t}$, com $k = -\frac{N}{2}, \dots, +\frac{N}{2}$ e Δt é o intervalo de amostragem (SAVI, 2006).

Um exemplo grosseiro de espectro de potências é dado pelos “leds” de um equalizador, em que as barras luminosas indicam a potência instantânea em cada uma das faixas de frequência de interesse, que nesse caso é a faixa audível (FIDLER-FERRARA & PRADO, 1994).

A caracterização por *FFT* é mais adequada em sistemas de baixa dimensão de imersão, com $m = 3$, ou seja, um sistema tri-dimensional (SAVI, 2006). Em sistemas com muitas dimensões (hiperespaço), o uso de *FFT* pode não ser vantajoso (MOON,

2004). Isso ocorre pois, se por um lado, em séries periódicas observa-se um espectro discreto de frequência, por outro, em séries não lineares e em séries aleatórias observa-se um espectro de banda larga. Desta forma, este método não é eficiente e necessita outras ferramentas para caracterizar o comportamento não linear de séries temporais (MOON, 2004; SAVI, 2006).

2.2.3. Teste Surrogate SUR

Para distinguir entre a não linearidade e a aleatoriedade de séries temporais, foi sugerido o teste surrogate (*SUR*) (THEILER et al., 1992; PROVENZALE et al., 1992; THEILER et al., 1993), o qual consiste em estimar as frequências dominantes por *FFT*, retirá-las da série temporal, depois embaralhar essas frequências dominantes uniformemente, e em seguida aplicar a transformada de Fourier inversa, reconstruindo a série temporal novamente, mas com as frequências dominantes embaralhadas (OTT, 1993). A série temporal obtida com este processo é aleatória, já que o teste surrogate destrói as correlações existentes com a série temporal que lhe deu origem, porém, são mantidas as mesmas propriedades espectrais (amplitude e fase de Fourier) e a mesma distribuição estatística que os dados originais (OTT, 1993; SCHREIBER & SCHMITZ, 1996; 2000). Se os invariantes topológicos são determinados apenas pela forma do espectro (ou equivalente pela $ACF(\tau)$), então eles não são afetados pelas fases embaralhadas. A preservação dos invariantes topológicos (como dimensão de correlação e expoentes de Lyapunov, que serão tratados a seguir) sobre as fases embaralhadas sugere fortemente que tais estimativas não indicam uma dinâmica caótica (CAMPANHARO et al., 2008).

O procedimento desse teste estatístico é o de aceitar ou rejeitar a hipótese nula. Admitindo-se a hipótese nula seja que a série temporal foi gerada por um processo estacionário estocástico gaussiano, rejeitar a hipótese nula ao nível de significância determinado ($p < 0,05$) significa que a estrutura não linear e seus invariantes topológicos ainda estão preservados no surrogate (OTT, 1993; SCHREIBER & SCHMITZ, 1996; 2000) conforme observa-se na Figura 2.

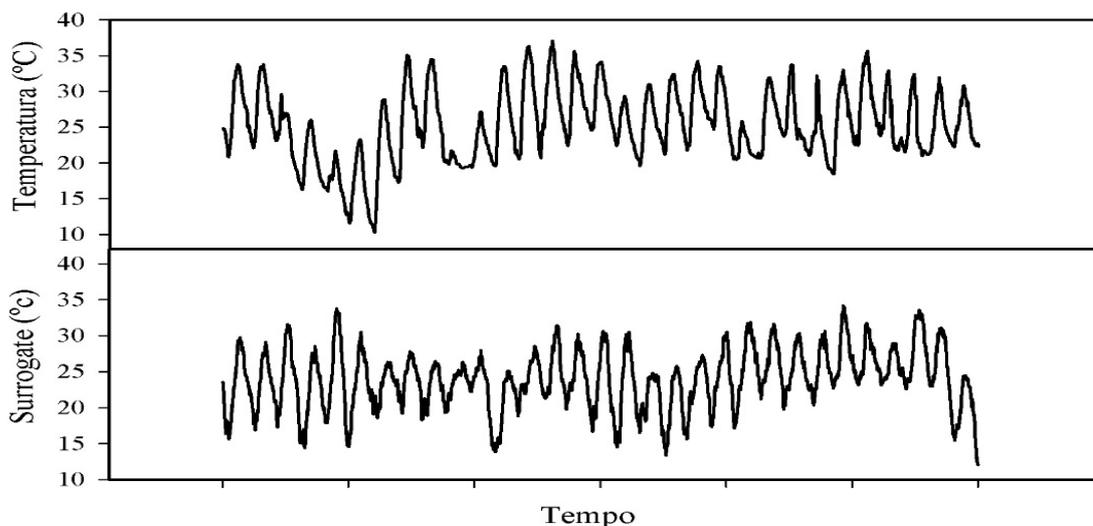


Figura 2. Série temporal de temperatura (superior) e seu respectivo surrogate (inferior) (MELLO et al., 2012b).

A correspondência entre a série original e a série surrogate é dada em termos de discrepância relativa (regressão linear) que se aproxima de zero com o aumento do número de interações de embaralhamento (HEGGER et al., 1999, MILLÁN et al., 2009). Este teste robusto é o mais utilizado na literatura para verificar a não linearidades de séries temporais experimentais (PRICHARD & THEILER, 1995; SIVAKUMAR et al., 1999; KANTZ & SCHREIBER, 2004; MIKSOVSKY & RAIDL, 2005; CHAKRABORTY & ROY, 2006, CAMPANHARO et al., 2008, MILLÁN et al., 2009, VARILOVA et al., 2011).

Caracterizada a série temporal como não linear e não aleatória, pode-se então, com segurança lançar mão do arcabouço teórico dos sistemas dinâmicos não lineares para a sua análise e predição. Nos próximos capítulos desta fundamentação teórica foram abordadas técnicas que são fundamentadas na reconstrução do espaço de fase.

2.3. RECONSTRUÇÃO DO ESPAÇO DE FASE

A teoria dos sistemas dinâmicos é uma matemática que permite aos cientistas lidar com a plena complexidade dos fenômenos não lineares; de modo que suas técnicas tornam os padrões subjacentes visíveis sobre formas distintas, e permitem identificar que o comportamento de muitos sistemas, por mais erráticos que sejam, exibem um nível mais profundo de ordem padronizada (CAPRA, 2006).

Essa matemática tem suas raízes no final do século XIX, pelas contribuições de Henri Poincaré que trouxe de volta à matemática a visualização, ou seja, trocou as tendências da análise e das fórmulas voltando novamente para os padrões visuais e de relações que veio a ficar conhecida como topologia, na qual todas as formas podem ser transformadas por meio de dobramentos, estiramentos e torções sendo “topologicamente equivalentes” (POINCARÉ, 1890; CAPRA, 2006).

Para a visualização de padrões complicados e aparentemente aleatórios os cientistas passaram então a utilizar um espaço matemático abstrato denominado “espaço de fase” (também chamado espaço de estados) (LORENZ, 1963; FIEDLER-FERRARA & PRADO, 1994; MOON, 2004; KANTZ & SCHREIBER, 2004; CAPRA, 2006).

Cada variável do sistema está associada com uma diferente coordenada neste espaço de fase. Um exemplo simples de compreensão é o de um movimento harmônico simples em um pêndulo ideal, o qual para ser descrito completamente necessita de duas variáveis, o ângulo e a velocidade (GLEICK, 1989). Ao se traçar um sistema de coordenadas no qual uma delas é o ângulo e a outra é a velocidade (Figura 3a), pode-se observar que quando a velocidade é igual a zero o ângulo é máximo, e quanto o ângulo é igual a zero a velocidade é máxima. Quando são marcados os pontos dos estados do movimento, observa-se que eles se distribuem num laço fechado, que é chamado de trajetória do espaço de fase, que descreve completamente o movimento do sistema (Figura 3b). Em qualquer momento é possível medir as duas coordenadas no espaço de fase e identificar o estado exato do sistema, sua velocidade e seu ângulo.

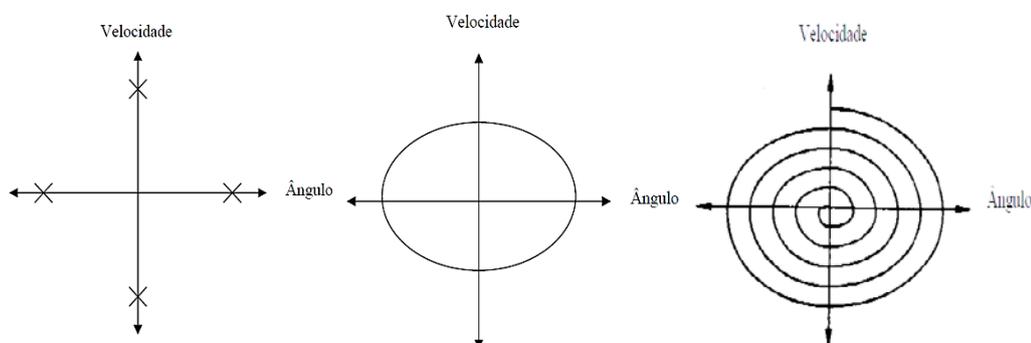


Figura 3. (a) O espaço de fase bidimensional de um pêndulo, (b) trajetória do pêndulo no espaço de fase, e (c) trajetória no espaço de fase de um pêndulo com atrito (adaptado de Capra, 2006).

Em sistemas reais, mais complicados e com mais variáveis utiliza-se a mesma técnica, representando cada variável por uma coordenada em uma dimensão diferente no espaço de fase, de modo que um único ponto neste espaço descreverá o estado de todo o sistema (CAPRA, 2006). Assim, na análise de um pêndulo real, no qual são consideradas variáveis como o atrito, que provoca a desaceleração até o pêndulo cessar o movimento, essa trajetória é representada por uma curva espiralada em direção ao centro, como na Figura 3c.

Assim como também afirmam Nicolis & Prigogine (1998), esse conjunto de trajetórias no espaço de fase é chamado de atrator, pois, matematicamente, o ponto fixo no centro das coordenadas atrai a trajetória, chamado de atrator pontual. Já na Figura 3b tem-se o chamado atrator periódico, pois apresenta uma trajetória em laço fechado.

Uma vantagem de se ver os estados como pontos no espaço é que isso torna mais fácil a observação da mudança, permitindo repensar o próprio sistema, suas periodicidades, torções correspondendo a mudanças, vazios correspondendo a impossibilidades físicas, enfim, um vislumbre do atrator do sistema (GLEICK, 1989).

Por definição, o atrator é um conjunto de atração em um espaço de fase. Esta região atrai todas as trajetórias das regiões vizinhas, e ao cair na chamada bacia de atração todas as trajetórias próximas se separam e adquirem uma estrutura muito complexa e enredada. Os atratores diferentes dos estados de equilíbrio e das oscilações rigorosamente periódicas recebem o nome de atratores estranhos (OSIPOV, 2003).

A aplicação mais famosa da aplicação destas técnicas data do ano de 1963, quando o meteorologista norte-americano Edward Lorenz apresentou um modelo desenvolvido para prever a convecção em fluidos, e que ganhou fama por apresentar comportamento caótico (LORENZ, 1963). O modelo de Lorenz busca representar a atmosfera terrestre que é aquecida pelo solo (maior absorvedor da radiação solar) e dissipa essa energia térmica para o espaço, ou seja, um modelo aquecido por baixo e resfriado por cima. Esse modelo compõe-se de três parâmetros de controle sendo ρ (número de Rayleigh), σ (número de Prandtl) e β (dimensões da região objeto de estudo); e ainda três variáveis, sendo x velocidade de convecção, y variação de

temperatura horizontal e z variação de temperatura vertical (LORENZ, 1963). O mesmo apresenta no espaço de fase um conjunto atrator diferente, com dinâmica quase-periódicas e estrutura fractal, que veio a ser chamado de atrator estranho ou atratores fractais, possuindo dimensionalidade fracionária, e exibindo extrema sensibilidade às condições iniciais. (RUELLE & TAKENS, 1971).

A partir das equações propostas por Lorenz (1963) em seu famoso artigo "Deterministic Nonperiodic Flow" construiu-se o atrator estranho, possuidor de um formato característico que lembra as asas de uma borboleta a partir de um conjunto de três equações diferenciais (Figura 4).

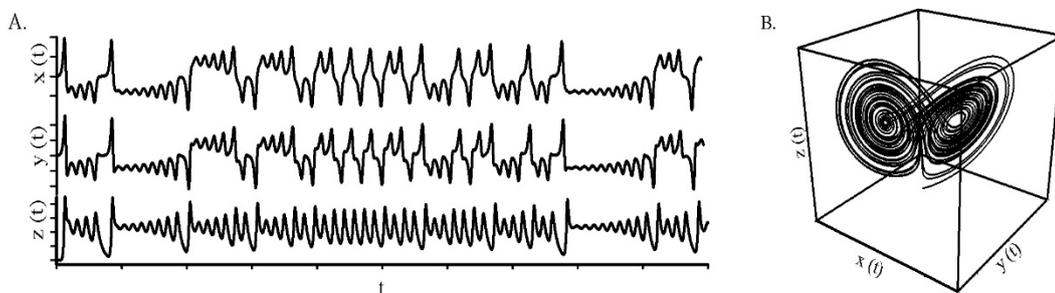


Figura 4. (A) solução numérica do sistema de equações de Lorenz (1963) para $x(t)$, $y(t)$ e $z(t)$ e (B) representação do espaço de fase tridimensional do atrator estranho de Lorenz (parâmetros de controle $\rho = 25$, $\sigma = 10$, $\beta = 8/3$).

A natureza está repleta de não linearidades que são responsáveis pela diversidade de comportamentos dos sistemas naturais. Os ritmos constituem uma das manifestações mais significativas dos sistemas naturais, podendo ser regulares ou não. Ritmos regulares podem estar associados a comportamentos normais e patológicos, o mesmo podendo ser dito sobre ritmos irregulares, ou caóticos (SAVI, 2006). Nosso mundo é cheio de instabilidades e flutuações que são, em última instância, responsáveis pela fantástica variedade e riqueza de formas e estruturas que são vistas na natureza (NICOLIS & PRIGOGINE, 1998).

Neste contexto, a descrição ou análise de fenômenos naturais através de modelos e técnicas não lineares é mais efetiva do que os modelos ou técnicas lineares (SAVI, 2006).

Partindo de uma série temporal experimental é possível analisar o sistema dinâmico que a gerou sem possuir informações detalhadas de sua dinâmica, ou seja, não possuindo um modelo matemático estabelecido. Neste contexto, acredita-se que

a ligação mais direta entre a teoria do caos e o mundo real é a análise de dados de séries temporais, nos termos da dinâmica não linear (KANTZ & SCHREIBER, 2004).

Baseados na teoria dos sistemas dinâmicos, os métodos de análise usado neste trabalho possibilitam estudar a dinâmica e as propriedades geométricas de séries temporais experimentais a partir da trajetória dos estados no espaço de fase reconstruído segundo o teorema de imersão (PACKARD et al., 1980; TAKENS, 1981). Em experimentos ambientais não é possível medir todas as variáveis do sistema, de forma que a partir da medida de uma única série temporal é possível reconstruir toda a estrutura geométrica da dinâmica e exibir as características das variáveis não medidas do sistema. Takens (1981) provou que o atrator reconstruído a partir dos eixos $Sn_{(x)}, Sn_{(x+\tau)}, Sn_{(x+2\tau)}, \dots, Sn_{(x+(m-1)\tau)}$, sendo $\tau = \tau\Delta t$ o tempo de defasagem, e m o espaço de imersão, é topologicamente equivalente ao atrator real.

Para efeito de ilustrar nesta fundamentação teórica os resultados dos métodos utilizados, optou-se por analisar três séries temporais teóricas para que possam ser relacionados com os resultados das séries temporais experimentais (Seção 4). As variáveis teóricas são: uma série determinística representada por uma senóide com fase de 96 dados, assim com a quantidade de dados de um dia com amostragem de 15 minutos chamada de variável *Seno*; uma série temporal proveniente da equação x do sistema caótico de Lorenz (1963) chamada variável *chaos*, e uma série temporal aleatória gerada com valores entre 0 e 1, chamada variável *random*. Abaixo, na Figura 5, foi apresentado a reconstrução tridimensional dos atratores associados a essas séries temporais teóricas.

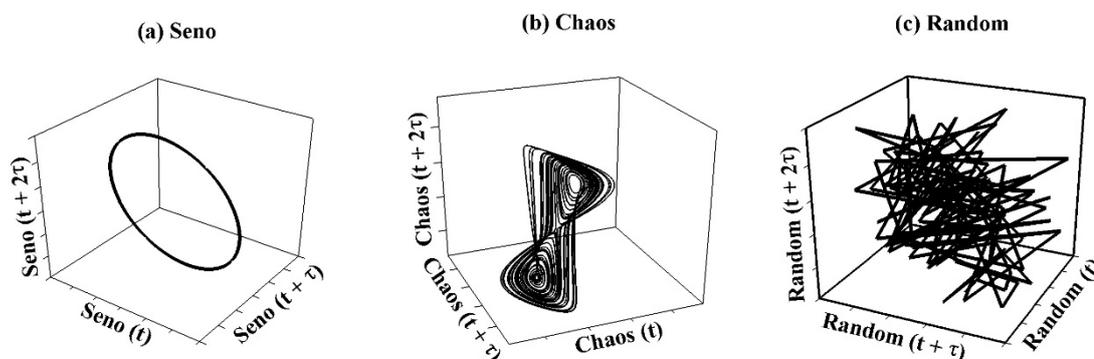


Figura 5. Reconstrução tridimensional dos atratores das variáveis teóricas

A correta reconstrução do atrator não é um processo automático, mas sim depende de duas escolhas fundamentais: o tempo de defasagem τ para que o atrator se desdobre de maneira correta e não fique fechado sobre si mesmo, e a dimensão de imersão m para evitar as falsas intersecções das órbitas do atrator. O efeito do tempo de defasagem temporal τ pode ser verificado no exemplo da Figura 6.

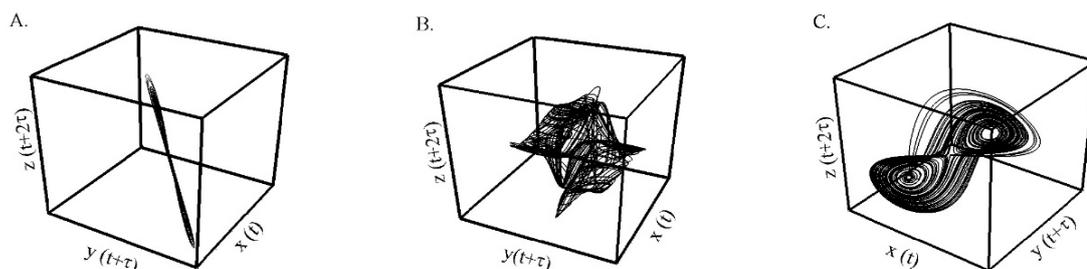


Figura 6. Efeito da defasagem temporal τ na reconstrução do atrator de Lorenz (1963) à partir da série x em um espaço de imersão $m=3$: (a) defasagem muito pequena, (b) uma defasagem muito grande e (c) para uma defasagem adequada (MELLO et al., 2013b).

2.3.1. Escolha do Tempo de Defasagem τ

Existem dois métodos muito utilizados para estimar o tempo de defasagem adequado: o primeiro é o método da função de autocorrelação ($ACF(\tau)$), que estima a medida da dependência linear entre um mesmo sinal defasado (FRASER & SWINNEY, 1986; BAKER & GOLLUB, 1996; ABARBANEL et al., 1993; KYOUNG et al., 2011) e o segundo, que estima a dependência não linear é chamado método da informação mútua MI (FRASER, 1989; ABARBANEL et al., 1993; ROULSTON, 1999).

2.3.1.1. Função de Autocorrelação $ACF(\tau)$

O tempo de defasagem τ adequado para a reconstrução do espaço de fase é encontrado quando a $ACF(\tau)$ atinge o valor zero ou o primeiro mínimo, característica da interdependência entre as medidas x e $x + \tau$. Em seguida plota-se $ACF(\tau)$ versus τ para visualizar a forma como a dependência da série cai com o τ entre pontos da série, assim como é apresentado na Figura 1.

Quando a série temporal do sistema estudado tem alguma periodicidade irregular, um valor pouco menor do que o período da série temporal é tipicamente escolhido (BAKER & GOLLUB, 1996). No entanto, a função de autocorrelação de uma série temporal multi-periódica com muitas frequências independentes e incomensuráveis também se confunde com aquela de uma série não linear, e desta forma a estimativa do tempo de defasagem τ com base na função de autocorrelação é comprometido (CAMPANHARO et al., 2008).

2.3.1.2. Informação Mútua $MI(\tau)$

Fraser & Swinney (1986) propuseram o uso da informação mútua ($MI(\tau)$) como uma forma de autocorrelação não linear para determinar o valor de τ adequado. Admite-se que os valores de x_n e $x_{n+\tau}$ sejam estatisticamente independentes o suficiente para serem coordenadas de um vetor com retardo, mas não demasiadamente independentes a ponto de não terem nenhuma conexão um com o outro (GOMES & VARRIALE, 2004). A reconstrução do espaço de fase utiliza o tempo de defasagem τ que corresponde ao primeiro mínimo obtido da $MI(\tau)$; o qual é obtido pela função:

$$MI(\tau) = - \sum_{x, x+\tau} Pr_{(x, x+\tau)} \ln \frac{Pr_{(x, x+\tau)}}{Pr_{(x)} Pr_{(x+\tau)}} \quad \text{Eq. 4}$$

onde $Pr_{(x)}$ é a probabilidade da medida x , $Pr_{(x+\tau)}$ é a probabilidade da medida $x + \tau$, e $Pr_{(x, x+\tau)}$ é a probabilidade da medida combinada de x e $x + \tau$, com $MI(\tau) \geq 0$ (MILLÁN et al., 2009; VIOLA et al., 2010).

A $MI(\tau)$ é uma função da probabilidade combinada de x e $x + \tau$. Se x e $x + \tau$ são iguais, então $MI(\tau)$ é máximo. Por outro lado se x e $x + \tau$ são completamente independentes, então o argumento do termo logarítmico é a unidade e $MI(\tau) = 0$. Assim, é estabelecido (FRASER & SWINNEY, 1986) que o valor ótimo do tempo de defasagem τ corresponde ao primeiro mínimo local da função $MI(\tau)$, quando ele ocorrer (Figura 7).

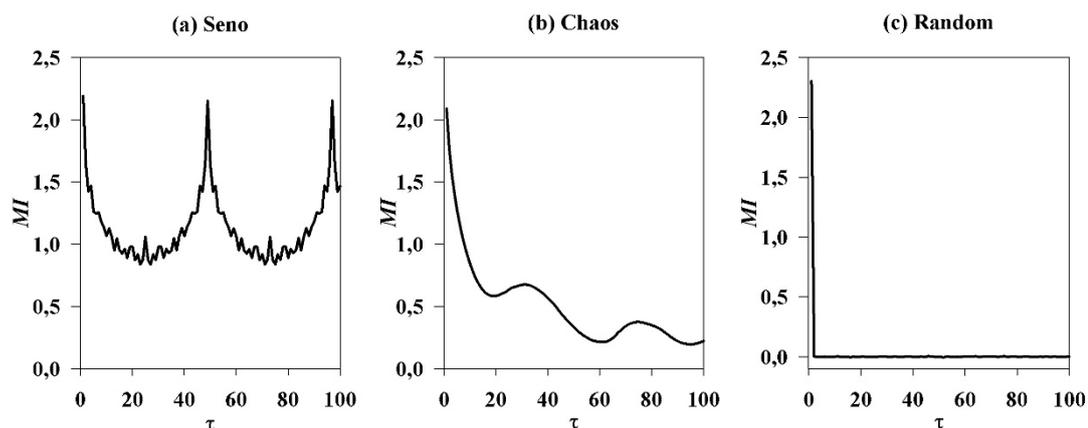


Figura 7. (a) Informação Mútua da série **Seno** com primeiro mínimo local igual a 24, (b) Informação Mútua da série **Chaos** X de Lorenz (1963) com primeiro mínimo local igual a 60, e (c) Informação Mútua da série **Random** com primeiro mínimo local igual a 1.

A $MI(\tau)$ fornece as mesmas informações que a função de autocorrelação fornece em um sistema linear sendo, na realidade, um tipo de generalização para sistemas não lineares (SAVI, 2006). Na maioria dos casos o método da informação mútua não fornece valores para τ substancialmente diferentes dos valores obtidos pela $ACF(\tau)$ (FIDLER-FERRARA & PRADO, 1994).

2.3.2. Escolha da Dimensão de Imersão m

Para a escolha da dimensão de imersão m , ou seja, dimensão real onde é imerso o conjunto atrator associado à série temporal experimental também existem dois métodos amplamente citados na literatura. O primeiro é o método da dimensão de correlação D_2 que para alguns casos também resulta em um m adequado a imersão do atrator (GRASSBERGER & PROCACCIA, 1983; KYOUNG et al., 2011). O outro método utilizado para determinar a melhor dimensão de imersão m é o método dos Falsos Vizinhos Próximos (FNN) (KENNEL et al., 1992; SAVI, 2006; VIOLA et al., 2010).

2.3.2.1. Dimensão de Correlação D_2

Em meados da década de 1980, Grassberger & Procaccia propuseram o algoritmo para a estimativa da Dimensão de Correlação D_2 de uma série temporal S_n

(GRASSBERGER & PROCACCIA, 1983) como a representação do número de variáveis que governam o sistema dinâmico do qual a série é proveniente. Ou seja, a D_2 provê o valor da Dimensão de Imersão m do espaço de fase onde o atrator está contido (GRASSBERGER & PROCACCIA, 1983; KYOUNG et al., 2011).

A D_2 (GRASSBERGER & PROCACCIA, 1983) é dada pela relação:

$$D_2 = \lim_{\varepsilon \rightarrow 0} \frac{\log C(\varepsilon)}{\log \varepsilon} \quad \text{Eq. 5}$$

onde $C(\varepsilon)$ é a função de correlação integral definida por:

$$C(\varepsilon) = \frac{1}{N^2} \sum_{\substack{i,j=1 \\ i \neq j}}^N \theta(\varepsilon - |x_i - x_j|) \quad \text{Eq. 6}$$

em que N é o número de pontos do atrator ou o comprimento da série temporal, $|\cdot|$ é a normal euclidiana que mede a distância entre os pares de vetores na Dimensão de Imersão m , e $\theta(\cdot)$ é a função de Heavyside, definida como:

$$\theta(\cdot) = \begin{cases} 1, & \text{se } x > 0 \\ 0, & \text{se } x \leq 0 \end{cases} \quad \text{Eq. 7}$$

Assim, a partir da nuvem de pontos do atrator em determinado espaço m dimensional, conta-se o número de pares $C(\varepsilon)$ com distâncias inferiores ao raio ε da hipersfera de sondagem, e, deste modo, variando o raio da hipersfera de sondagem ε de um valor infinitesimalmente pequeno até um valor que engloba todo o conjunto atrator no espaço de fase, obtém-se a relação:

$$C(\varepsilon) \sim \varepsilon^{D_2} \quad \text{Eq. 8}$$

Ou seja, a D_2 de um atrator é dada pela declinação $\ln C(\varepsilon)$ por $\ln \varepsilon$ para certa distância de ε :

$$\ln C(\varepsilon) = D_2 \ln \varepsilon \quad \text{Eq. 9}$$

Como na prática não se sabe qual é a Dimensão de Imersão m adequada para a correta reconstrução do atrator, deve-se calcular a integral de correlação $C(\varepsilon)$ para valores de m crescentes (de 1 até 20, por exemplo). Desta forma, para cada Dimensão de Imersão m obtém-se então um valor de $D_2(m)$ correspondente. Teoricamente a declinação de $\ln C(\varepsilon)$ por $\ln \varepsilon$ é aproximadamente igual ao valor de m se esse $m < D_2$ convergindo (se isso ocorrer) para um valor fixo de D_2 quando

esse m for suficientemente alto (FIEDLER-FERRARA & PRADO, 1994). Para que a convergência nos valores de $D_2(m)$, calculados para m crescente, possa ser confirmada, deve possibilitar a reconstrução e o cálculo de $D_2(m)$ até m da ordem de $2D_2 + 1$ (TAKENS, 1981). A Figura 8 ilustra isso.

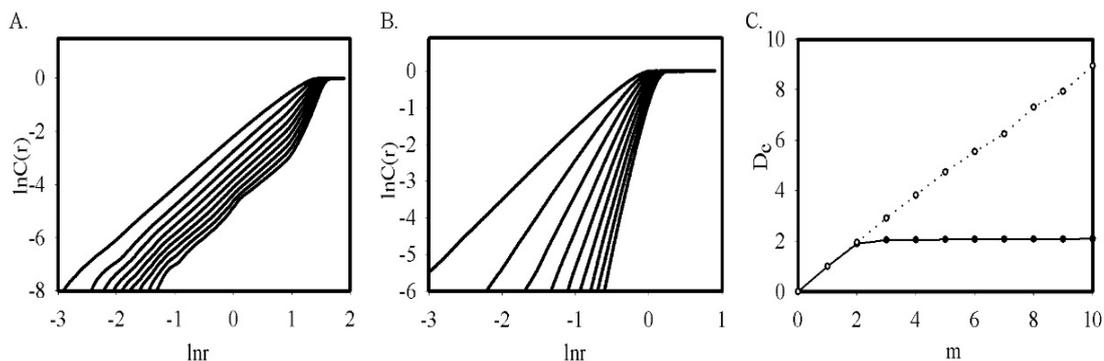


Figura 8. (a) $\ln C(r)$ vs $\ln r$ para valores crescentes de m para o atrator reconstruído a partir da série x de Lorenz, (b) $\ln C(r)$ vs $\ln r$ para uma série de dados aleatórios; e (c) saturação da dimensão de correlação versus dimensão de imersão m para o atrator reconstruído a partir da série x de Lorenz (1963) com $D_c \approx 2,05 \pm 0,01$ e $m = 3$ (●) e para a série aleatória com dimensão m infinita (○).

Grassberger & Procaccia (1983) afirmaram que séries temporais aleatórias ou estocásticas deveriam ser caracterizadas por um valor de m infinito, ou seja, os valores de $D_2(m)$ não saturariam quando calculados para m crescente porque não possuem um atrator. No entanto, Osborne & Provenzale (1989) demonstraram que uma série temporal de ruído “colorido”, caracterizada por lei de potência conduz a uma saturação de D_2 . Embora a mesma seja amplamente utilizada na literatura, isto torna o valor de D_2 , calculado pelo algoritmo de Grassberger e Procaccia (1983), não suficiente para afirmar a presença de atratores em sistemas dinâmicos não lineares.

Para solucionar este problema da determinação da mínima dimensão de imersão m , Kennel et al. (1992) propuseram o método dos falsos vizinhos próximos, que foi tratado na próxima Seção.

2.3.2.2. Falsos Vizinhos Próximos *FNN*

O método dos Falsos Vizinhos Próximos *FNN* para determinar a melhor Dimensão de Imersão m foi proposto por Matthew Kennel, Reggie Brown e Henry Abarbanel (KENNEL et al., 1992). Este método é baseado em uma ideia totalmente intuitiva, que busca um m onde não ocorra cruzamento da órbita do atrator consigo

mesma. O procedimento consiste em aumentar a dimensão m , do espaço de fase reconstruído a partir da série temporal S_n , com o tempo de defasagem τ que constitui os vetores, e examinar seus vetores vizinhos próximos, verificando se a proximidade na vizinhança é verdadeira, isto é, se decorre da dinâmica verdadeira que rege o sistema ou trata-se de uma proximidade apenas de projeções de dimensão superior (KANTZ & SCHREIBER, 2004; SAVI, 2006) (Figura 9).

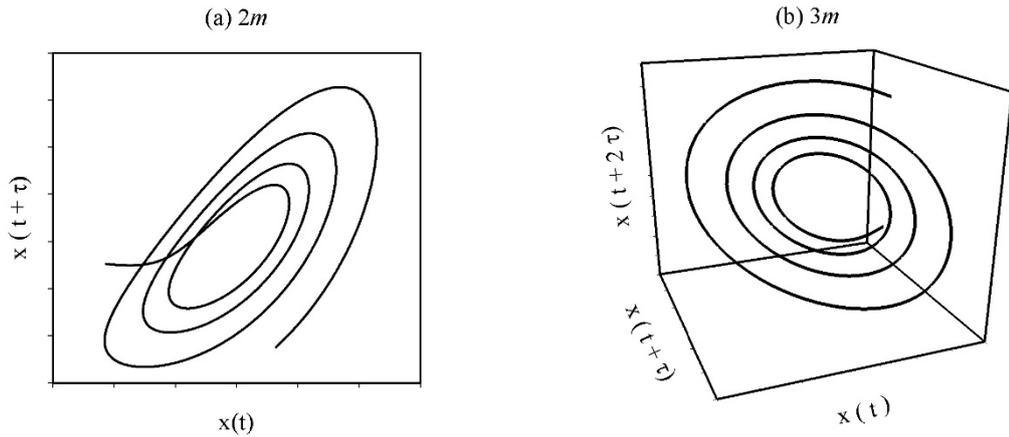


Figura 9. Esquema representativo do método FNN para: (a) duas dimensões de imersão m com falsas trajetórias interceptadas (falsos vizinhos) e (b) com três dimensões de imersão m sem falsas interceptações.

O procedimento pode ser interrompido quando for observado que um acréscimo em m não resulta em redução do número de falsos vizinhos próximos, encontrando o número inteiro m necessário para desdobrar S_n , ou seja, explicitar inteiramente o atrator em um espaço m -dimensional completo da dinâmica do sistema (GOMES & VARRIALE, 2004; SAVI, 2006; VIOLA et al., 2010).

O algoritmo para verificar se, com um determinado m , a proximidade na vizinhança é falsa ou verdadeira procura o vizinho próximo x_j de cada ponto x_i de S_n . Então, obtém-se a distância $|x_i - x_j|$ e, em seguida, repete-se ambos os pontos com $m + 1$ e calcula-se:

$$FNN_i = \frac{|x_{i+1} - x_{j+1}|}{|x_i - x_j|} \quad \text{Eq. 10}$$

Se o valor encontrado para esta razão aumentar, constata-se a falsidade desta proximidade, pois significa que, quando se aumenta a Dimensão de Imersão m , os pontos que por “acaso” eram próximos passam a se afastar; se por outro lado este valor não aumenta, conclui-se que tal proximidade na vizinhança é verdadeira, isto é,

tais pontos são vizinhos próximos, no atrator verdadeiro gerado pela dinâmica do sistema (GOMES & VARRIALE, 2004) (Figura 10).

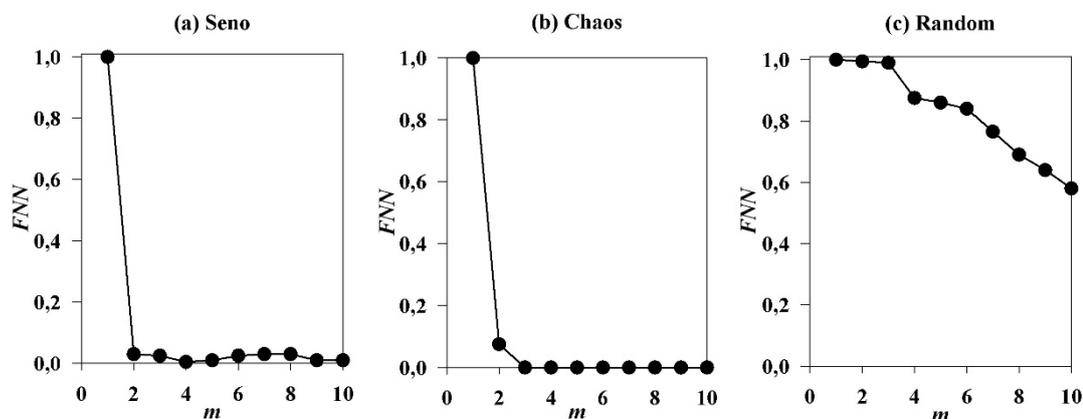


Figura 10. Fração de falsos vizinhos mais próximos FNN , em função da dimensão de imersão m das séries temporais (a) Seno, (b) Chaos e (c) Random.

2.4. ANÁLISE DE SÉRIES TEMPORAIS NÃO LINEARES

Partindo de uma série temporal experimental S_n , e reconstruído o espaço de fase pelo método dos atrasos temporais, com tempo de defasagem τ e dimensão de imersão m adequados, desdobra-se a estrutura do atrator estranho associado ao sistema ambiental (NICOLIS & PRIGOGINE, 1998). Este atrator reconstruído mantém as mesmas características topológicas do atrator real do sistema, preservando as propriedades invariantes como estrutura e dinâmica. Desta forma, a sua complexidade pode ser mensurada em termos qualitativos e quantitativos a partir de métodos não lineares de análise de séries temporais (KANTZ & SCHREIBER, 2004; GOMES & VARRIALE, 2004; SAVI, 2006; CAMPANHARO et al., 2008; VIOLA et al., 2010)

Segundo a abordagem por teoria dos sistemas dinâmicos (KANTZ & SCHREIBER, 2004), descreve-se a seguir os métodos não lineares de análise da dinâmica das séries temporais utilizados neste trabalho: Gráficos de Recorrência RP , e as suas ferramentas de Análise Quantitativa de Recorrência RQA , o Expoente de Lyapunov λ e a Dimensão de Correlação D_2 .

2.4.1. Gráficos de Recorrência *RP*

Da ideia inicial de Poincaré (1890) que “negligenciando algumas trajetórias excepcionais, o sistema recorre infinitamente tão perto quanto se queira do seu estado inicial”, Eckmann et al. (1987) propuseram a ferramenta Gráfico de Recorrência *RP* que permite a visualização da dinâmica de sistemas recorrentes.

Geralmente o espaço de fase de um experimento real tem mais de três dimensões, o que permite que ele seja adequadamente retratado (SAVI, 2006). Espaços de fase com dimensões mais elevadas (hiperespaço) só podem ser visualizados pela projeção em subespaços de duas ou três dimensões, por isso a ferramenta de Eckmann et al. (1987) permite investigar a trajetória m -dimensional do espaço de fase por meio de uma representação bidimensional de suas repetições. A recorrência de um estado i em um tempo diferente j é marcada dentro de uma matriz bidimensional quadrada com pontos 1 e 0 (pontos pretos e brancos respectivamente), onde ambos os eixos são eixos de tempo. Esta representação é o próprio Gráfico de Recorrência *RP*, que pode ser expresso matematicamente como:

$$RP_{i,j} = \theta(\varepsilon - |x_i - x_j|), \quad x_i \in \mathbb{R}^m, \quad i, j = 1, \dots, N, \quad \text{Eq. 11}$$

em que N é o número de estados considerados x_i , ε é o raio da vizinhança (threshold), $|\cdot|$ é a norma da vizinhança (comumente a norma euclidiana), $\theta(\cdot)$ é a função de Heaviside e m é a Dimensão de Imersão.

Com ε -estados recorrentes, isto é, com estados que estejam em uma região de vizinhos em um raio ε , se introduz a notação dada na Equação (11) (MARWAN et al., 2007):

$$x_i \approx x_j \Leftrightarrow R_{i,j} \equiv 1 \quad \text{Eq. 12}$$

O Gráfico de Recorrência é obtido plotando-se a matriz de recorrência e traçando-se um ponto para as coordenadas (i, j) se $R_{i,j} \equiv 1$, e um ponto branco se $R_{i,j} \equiv 0$. O *RP* sempre tem uma linha diagonal principal, a linha de identidade. Além disso, o *RP* é simétrico no que diz respeito a diagonal principal (MARWAN et al., 2007).

O propósito inicial de *RP* é a inspeção visual de trajetórias em espaços de fase de altas dimensões. A visão de um *RP* dá sugestões sobre a evolução temporal

destas trajetórias. Outra vantagem é que eles também podem ser aplicados a conjuntos de dados curtos e não estacionários (Figura 11) (MARWAN et al., 2007).

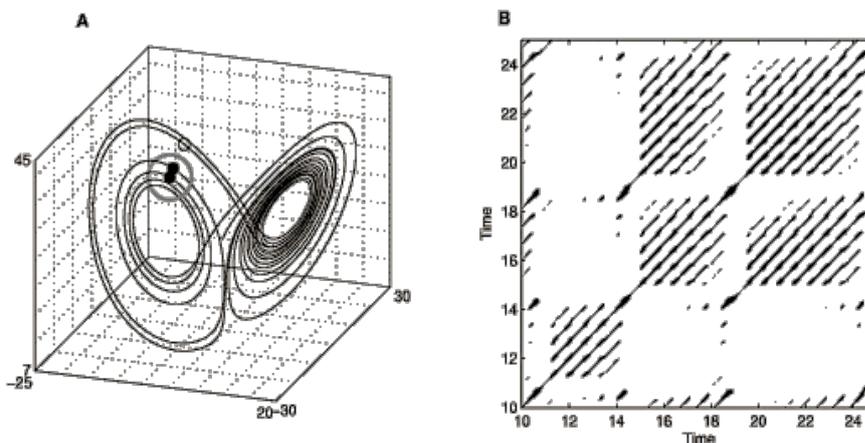


Figura 11. Onde (A) é segmento da trajetória no espaço de fase do sistema de Lorenz (parâmetros de controle $r = 28$, $\sigma = 10$, $b = 03/08$; Lorenz, 1963), usando as três componentes x , y e z ; e (B) correspondente a sua parcela de recorrência. Um ponto da trajetória de j dentro da vizinhança (círculo cinza em (A)) de um determinado ponto no i é considerado como um ponto de recorrência (ponto preto sobre a trajetória de (A)). Este é marcado com um ponto preto no RP no local (i, j) . Um ponto fora da vizinhança (pequeno círculo de (A)) provoca um ponto branco no RP . O raio da vizinhança para o RP é $\varepsilon = 5$ (Disponível em <http://www.recurrence-plot.tk/glance.php> acesso em 12/2011).

Os gráficos de recorrência exibem características de grande escala e padrões de pequena escala. Os primeiros padrões de forma denotados foram a tipologia e a textura conforme a Figura 12 (ECKMANN et al., 1987).

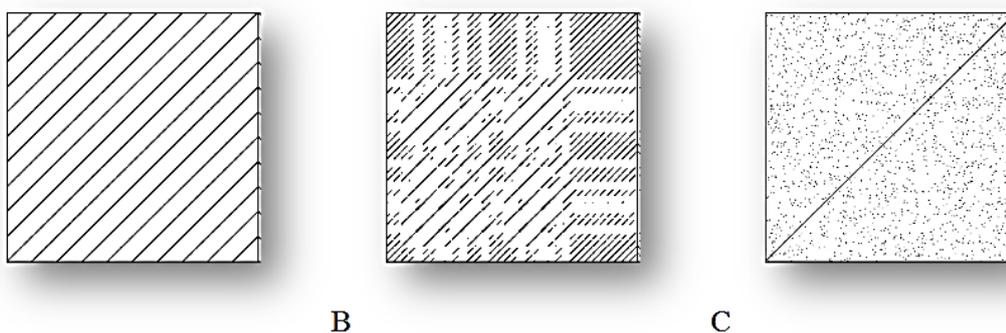


Figura 12. Gráficos de Recorrência de (A) movimento periódico de uma frequência, (B) atrator estranho de Rössler (parâmetros $a=b=0.2$ e $c=5.7$) e (C) ruído branco (MARWAN et al., 2007).

A tipologia oferece uma impressão global que pode ser caracterizada como homogênea, flutuante, periódica e desvios. Sistemas homogêneos; em que tempos de relaxação são curtos em comparação com o tempo abrangido pelo gráfico de recorrência; como exemplo, tem-se um RP de uma série temporal de dados

aleatórios (ECKMANN et al., 1987; MARWAN et al., 2007). Sistemas oscilantes: contêm diagonais orientadas, estruturas periódicas recorrentes (linhas diagonais, estruturas quadriculadas). Em sistemas quase-periódicos, as distâncias entre as linhas diagonais são diferentes. No entanto, mesmo em sistemas oscilantes, cujas oscilações não são facilmente reconhecíveis, o *RP* pode ser utilizado a fim de encontrar suas oscilações. Sistemas não estacionários são os desvios causados por sistemas com parâmetros de variação lenta. Tal mudança lenta (adiabática) ilumina o canto superior esquerdo e inferior direito do *RP*. Mudanças abruptas na dinâmica, bem como eventos extremos causam áreas brancas ou bandas no *RP* (MARWAN et al., 2007).

A Textura é caracterizada por estruturas de pequena escala observadas em uma inspeção mais refinada dos *RPs*. São pontos isolados, linhas diagonais, bem como linhas verticais e horizontais (a combinação de linhas verticais e horizontais, formas retangulares aglomerados de pontos de recorrência). Podem ocorrer pontos de recorrência isolados se os estados são raros, se não persistir por muito tempo ou se eles oscilam muito. No entanto, eles não são um sinal exclusivo do acaso ou de ruído (por exemplo, em mapas de atratores estranhos).

A linha diagonal $R_{i+k,j+k} = 1$ (para $k = 1, \dots, l$ (onde l é o comprimento da linha diagonal) ocorre quando um segmento da trajetória segue paralelo a outro segmento, ou seja, a trajetória visita a mesma região do espaço de fase em momentos diferentes. O comprimento desta linha diagonal principal é determinado pelo tempo de duração semelhante da evolução local dos segmentos de trajetória. A direção dessas estruturas diagonais pode ser diferente. Linhas diagonais paralelas à linha principal representam trajetórias paralelas seguindo uma mesma evolução temporal. As estruturas diagonais perpendiculares à linha diagonal principal representam um seguimento de evolução contrária (MARWAN et al., 2007).

A linha vertical (horizontal), $R_{i,j+k} = 1$, para $k = 1, \dots, v$, onde v é o comprimento da linha vertical) marca um período de tempo em que um estado não muda ou muda muito lentamente. Ao que parece estes estados são presos por algum tempo, comportamento típico de estados laminares (intermitência).

Estas estruturas de pequena escala são a base da Análise de Quantificação de Recorrência *RQA*, que será tratada na próxima Seção (MARWAN et al., 2007).

2.4.2. Análise Quantitativa de Recorrência

As estruturas do gráfico de recorrência RP possibilitam por si só caracterizar os sistemas dinâmicos através das suas diferentes tipologias, que por sua vez são fundamentadas nas quantidades relacionadas ao padrão de pequena escala, a chamada textura do RP . A quantificação relacionada à textura do RP , baseada tanto na densidade de recorrência quanto nas quantidades e tamanhos das linhas diagonais e verticais (horizontais), é o que se chama de Análise Quantitativa de Recorrência (RQA).

Assim, a Análise Quantitativa de Recorrência (RQA) é a medida da complexidade do sistema, um método não linear que quantifica o número e duração das recorrências de um sistema dinâmico representado por sua trajetória no espaço de fase das variáveis. A RQA foi desenvolvida por Zbilut & Webber Jr (ZBILUT & WEBBER Jr., 1992; WEBBER Jr & ZBILUT, 1994) e estendido com novas medidas por Marwan et al. (2002).

Delimitou-se neste trabalho quatro Análises Quantitativas de Recorrência que são profundamente discutidas em Marwan et al. (2007). São elas: a Razão de Recorrência RR , o determinismo DET , o Comprimento Médio da Diagonal L e a Entropia $ENTR$.

2.4.2.1. Razão de Recorrência RR

A Razão de Recorrência RR mede a densidade de pontos de recorrência no GR, definido pela equação:

$$RR(\varepsilon) = \frac{1}{N^2} \sum_{i,j=1}^N R_{i,j}(\varepsilon) \quad \text{Eq. 13}$$

A RR não exclui a diagonal principal e, no limite $N \rightarrow \infty$ é a probabilidade de que um estado retorne à sua vizinhança de raio ε no espaço de fase (MARWAN et al., 2007).

2.4.2.2. Determinismo **DET**

O determinismo *DET* é a medida de previsibilidade do sistema, definido pela equação abaixo:

$$DET = \frac{\sum_{l=l_{min}}^N lP(l)}{\sum_{l=1}^N lP(l)} \quad \text{Eq. 14}$$

em que N é o número de elementos da série temporal, $P(l)$ é o número de diagonais de comprimento l no *RP*, e l_{min} é o menor tamanho para uma linha ser considerada uma diagonal (MARWAN et al., 2007).

2.4.2.3. Comprimento Médio da Diagonal **L**

A medida Comprimento Médio da Diagonal L é a razão entre o número de pontos pertencentes às diagonais $lP(l)$ (exceto diagonal principal) pelo número das diagonais $P(l)$, dado por:

$$L = \frac{\sum_{l=l_{min}}^N lP(l)}{\sum_{l=l_{min}}^N P(l)} \quad \text{Eq. 15}$$

Esta medida de complexidade representa o tempo médio em que dois segmentos da trajetória estão próximos um do outro, e pode ser interpretado com o tempo médio de previsão.

2.4.2.4. Entropia **ENTR**

A medida *ENTR* refere-se à entropia de Shannon da probabilidade $p(l) = P(l)/N_l$ para uma linha diagonal de comprimento l no *RP* (N_l é o número total de diagonais do *RP*):

$$ENTR = - \sum_{l=l_{min}}^N p(l) \ln p(l) \quad \text{Eq. 16}$$

Esta medida reflete a complexidade do *RP* com respeito às linhas diagonais. Um *RP* homogêneo gerado a partir de uma série de dados aleatórios não apresenta muitas diagonais, e resulta num baixo valor de entropia, que por sua vez indica baixa complexidade (MARWAN et al., 2007).

A seguir, são descritos os resultados da RQA para as séries temporais teóricas (Figuras 13, 14 e 15), visto servirem de referência de interpretação dos resultados

que são descritos na Seção 4.4.1, que trata da análise das séries temporais micrometeorológicas medidas.

A série temporal teórica *seno*, quanto a sua variância, apresentou valor constante e igual a 1, que é justamente a amplitude da senóide. A série *chaos*, quanto a variância, teve um comportamento não-linear que acompanha a dinâmica caótica da série, enquanto a *random* oscilou aleatoriamente e não seguiu um padrão.

Quanto medidas da *RQA* para RR_{seno} , ela permaneceu em um patamar de 1%. A RR_{chaos} apresentou picos de recorrência com amplitudes de 20% e 40% nos momentos em que a série temporal oscilou periodicamente, e manteve-se próxima de 1% nos trechos em que a série *chaos* oscilou caoticamente. A RR_{random} apresentou um comportamento aleatório.

A série *seno*, variável linear altamente determinística, obteve para DET_{seno} valor constante igual a 1. A DET_{chaos} variou de valores muito próximos a 1 até valores próximos a 0,98. Importante ressaltar que se usa uma janela pequena para a análise e que desta forma o determinismo se refere justamente ao tamanho da janela, e que as mudanças no padrão do DET_{chaos} indicando uma dinâmica que muda constantemente fazem com que sua previsibilidade também varie, tornando a série *chaos* pouco previsível quando a sua dinâmica é considerada como um todo. A medida DET_{random} da variável *random* manteve-se, como esperado, constantemente no patamar zero.

O tempo médio em que duas trajetórias do atrator estão próximas uma da outra é dado pela medida L . A variável *seno* apresentou L_{seno} constante. A de L_{chaos} apresentou um valor oscilante não-linear permitindo identificar os picos dos momentos em que sistema adota oscilações periódicas mais prolongadas e também as flutuações quando o sistema varia constantemente o seu período. A variável *random* obteve como resultando de L_{random} o valor zero.

A medida de entropia, $ENTR$, foi constante e diferente de zero para o $ENTR_{seno}$. A variável *chaos* apresentou $ENTR_{chaos}$ com flutuações e alguns picos não lineares característico da série. Quanto à série *random*, sua medida de $ENTR_{random}$ foi nula, o que se justifica teoricamente por ser aleatória e já estar no patamar máximo de desconexão entre os dados da própria série.

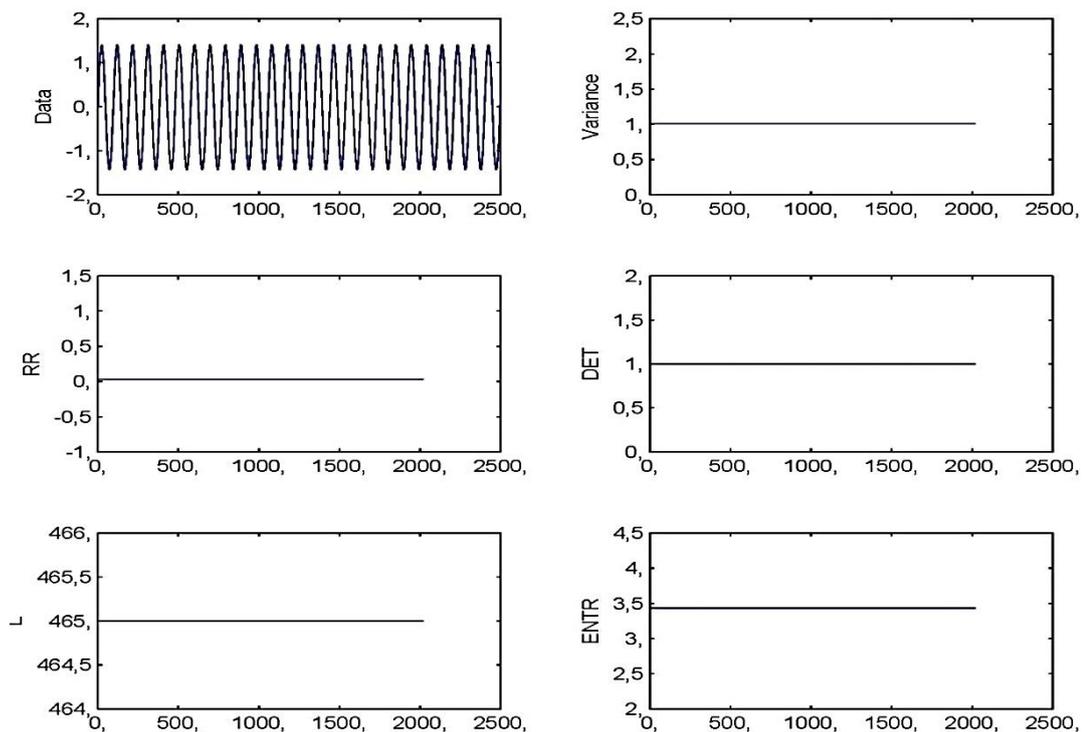


Figura 13. Análise de Quantificação de Recorrência *RQA* da variável teórica *seno*.

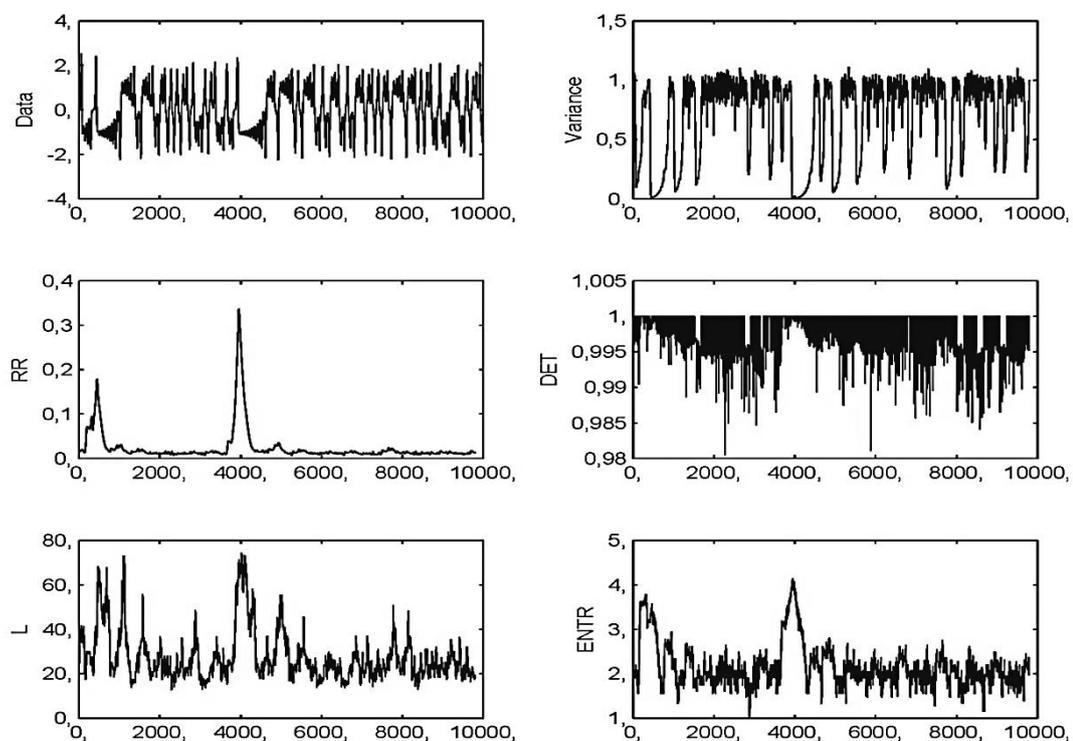


Figura 14. Análise de Quantificação de Recorrência *RQA* da variável teórica *chaos*.

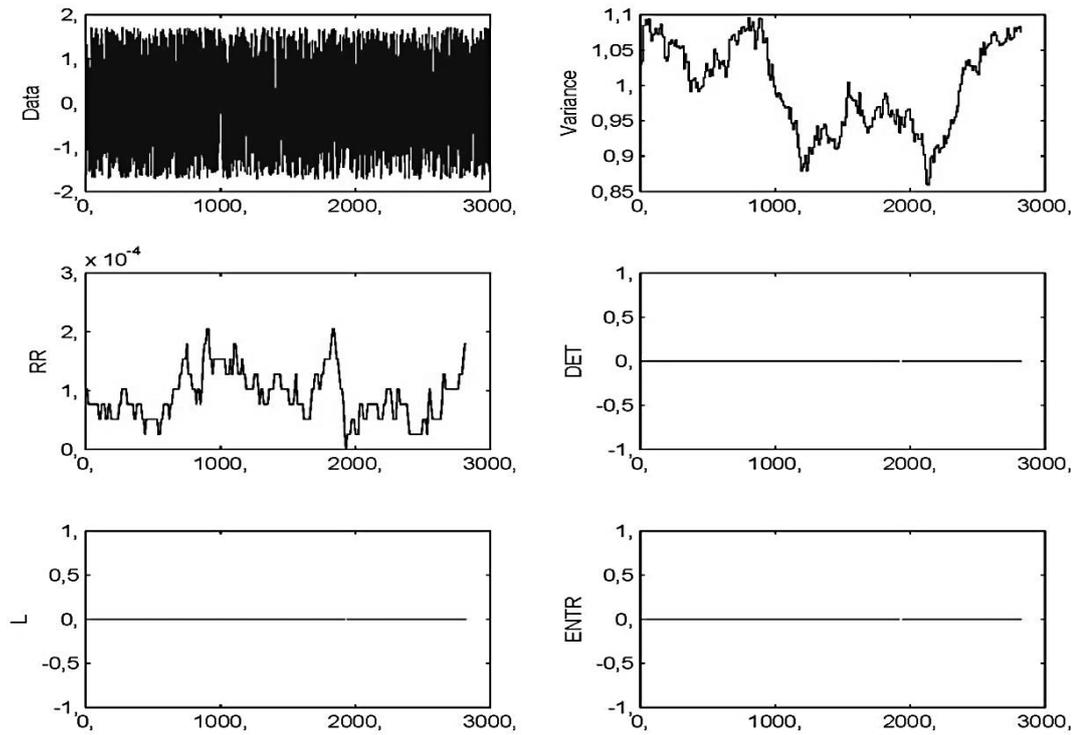


Figura 15. Análise de Quantificação de Recorrência **RQA** da variável teórica **random**.

2.4.3. Expoentes de Lyapunov λ

O Expoente de Lyapunov λ é um parâmetro que provê informação sobre a taxa média na qual as trajetórias divergem ou convergem dentro do atrator. Um λ positivo indica comportamento caótico; enquanto λ negativo ou nulo representa estabilidade ou comportamento cíclico.

Para uma caracterização confiável é necessário que a independência dos parâmetros de imersão m e da lei exponencial de divergência das trajetórias sejam verificadas claramente, ou seja, deve-se calcular λ para diferentes Dimensões de Imersão m (ROSENSTEIN et al., 1993; KANTZ, 1994). Da série temporal genérica $S_n = S(x_n)$ com $n = 1, \dots, N$, considera-se então a trajetória do atrator num espaço de imersão m -dimensional, e admite-se observar um retorno $S_{n'}$ muito próximo do ponto S_n . Em seguida considera-se a distância entre esses pontos, $\Delta_0 = S_n - S_{n'}$ como uma pequena perturbação da órbita do atrator que cresce exponencialmente com o tempo. A projeção futura pode ser compreendida a partir da $\Delta_1 = S_{n+1} - S_{n'+1}$. Constatado que $|\Delta_1| \approx \Delta_0 e^{\lambda_1}$, então λ é o máximo expoente de Lyapunov.

Para prover consistentemente um estimador robusto e imparcial para o máximo expoente de Lyapunov λ computa-se:

$$S(\varepsilon, m, \tau) = \left\langle \ln \left(\frac{1}{|u_n|} \sum_{S_{n', \varepsilon u_n}} |S_{n+\tau} - S_{n'+\tau}| \right) \right\rangle \quad \text{Eq. 17}$$

onde m é a dimensão de imersão, $\tau = \tau \Delta t$, e u_n é a vizinhança do ponto S_n com diâmetro ε . Plota-se $S(\varepsilon, m, \tau)$ por τ e se exibir um crescimento linear com inclinação idêntica para todo m maior que alguns m_0 e para uma extensão de ε , então esta inclinação pode ser tomada como uma estimativa de λ_{max} , assim como na Figura 16.

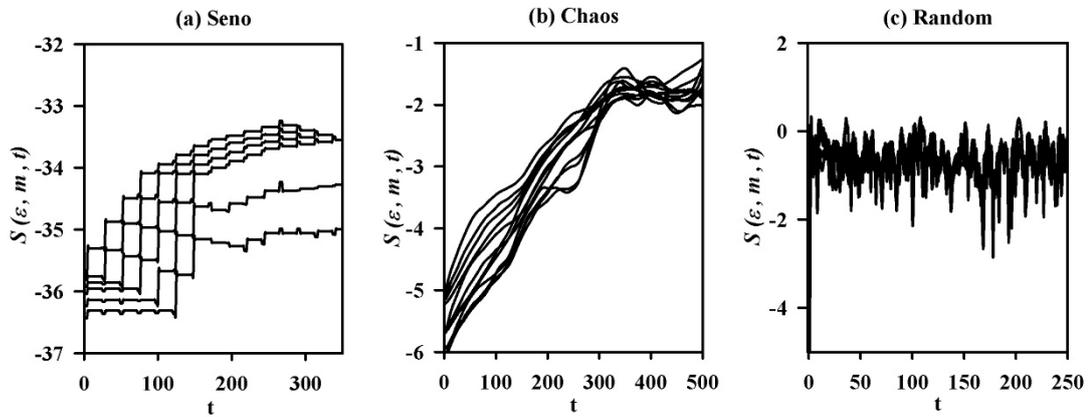


Figura 16. Estimativa do maior expoente de Lyapunov para a (a) reconstrução do atrator da série Seno sem divergência exponencial das trajetórias, (b) reconstrução do atrator associado a série Chaos [Lorenz (1963) a partir da variável x , $\tau = 60$, parâmetros de controle $\rho = 25$, $\sigma = 10$, $\beta = 8/3$, passo de 0,01 segundo com m crescente de 1 a 3, obtendo $\lambda_{max} = 0,0092$] e (c) reconstrução do atrator da série Random também não apresentando divergência exponencial das trajetórias.

Outro ponto importante é a característica dinâmica dos sistemas não lineares, no que diz respeito à sensibilidade às condições iniciais (SCI): uma pequena perturbação na configuração inicial do sistema promove a curto prazo uma grande divergência nas trajetórias. Este fato que reporta ao “efeito borboleta” observado primeiramente no modelo de Lorenz (1963) do atrator borboleta, aplica-se também às séries temporais ambientais, mas com uma diferença: cada um dos pontos da série temporal analisada pode ser considerado como a condição inicial, desde que se queira fazer uma previsão daquele instante em diante.

A ideia básica aqui é identificar pequenas quantidades que não são alteradas quando as condições iniciais de uma dada órbita são modificadas ou, alternadamente, quando é introduzida uma perturbação em algum ponto da órbita.

2.4.4. Dimensão de Correlação D_2

As soluções dos sistemas dinâmicos dissipativos não podem preencher um volume do espaço de fase, uma vez que a dissipação é um sinônimo de uma contração do elemento de volume sob a ação das equações do movimento (SAVI, 2006). Os sistemas dinâmicos que exibem comportamento caótico apresentam trajetórias no espaço de fase que convergem para um atrator estranho (GRASSBERGER & PROCACCIA, 1983). A estranheza desse atrator caótico é relacionada com sua dimensão fractal, uma alusão ao termo fracionário, caracterizando uma dimensão não inteira (KANTZ & SCHREIBER, 2004). Esta dimensão fractal fornece a informação necessária para especificar a posição de um ponto no atrator com certa precisão (FIEDLER-FERRARA & PRADO, 1994).

Assim como λ_{max} é uma medida quantitativa da não linearidade da dinâmica no sentido da instabilidade, a Dimensão de Correlação D_2 é a medida da não linearidade da geometria no sentido da auto similaridade do atrator. Ou seja, o grau em que a presença de um ponto afeta a posição dos outros pontos dispostos na trajetória no espaço de fase (KANTZ & SCHREIBER, 2004).

A noção geométrica euclidiana de dimensão para objetos não fractais é que para um ponto a dimensão é igual a zero, para uma linha a dimensão é igual a um, para superfícies a dimensão é igual a dois, e por fim, para objetos a dimensão é igual a três. No entanto, no espaço de fase os conjuntos atratores associados a sistemas reais não ocupam totalmente o volume deste espaço, possuindo desta maneira, uma dimensão não inteira e geralmente maior do que três (CAPRA, 2006).

O método da Dimensão de Correlação D_2 utiliza a Correlação Integral (Eq.6) para determinar essa dimensão de particular interesse, a dimensão fractal dos atratores e, portanto, para distinguir entre os sistemas de baixa dimensão e alta dimensão. Reconstruídos os atratores teóricos de acordo com os parâmetros apresentados nas Seções 2.3.1.2 e 2.3.2.2, e variando a dimensão de imersão m de 1 até 10 obteve-se os seguintes resultados para as séries teóricas: $D_{2(seno)} = 1,0 \pm 0,0$ com $m_{(seno)} = 2$ assim como se esperava teoricamente, a $D_{2(chaos)} = 2,05 \pm 0,01$ com $m_{(chaos)} = 3$ valor de acordo com a bibliografia e por fim a $D_{2(random)}$

que não apresentou saturação de $m_{(random)}$ (GRASSBERGER & PROCACCIA, 1983). Isto foi apresentado na Figura 17.

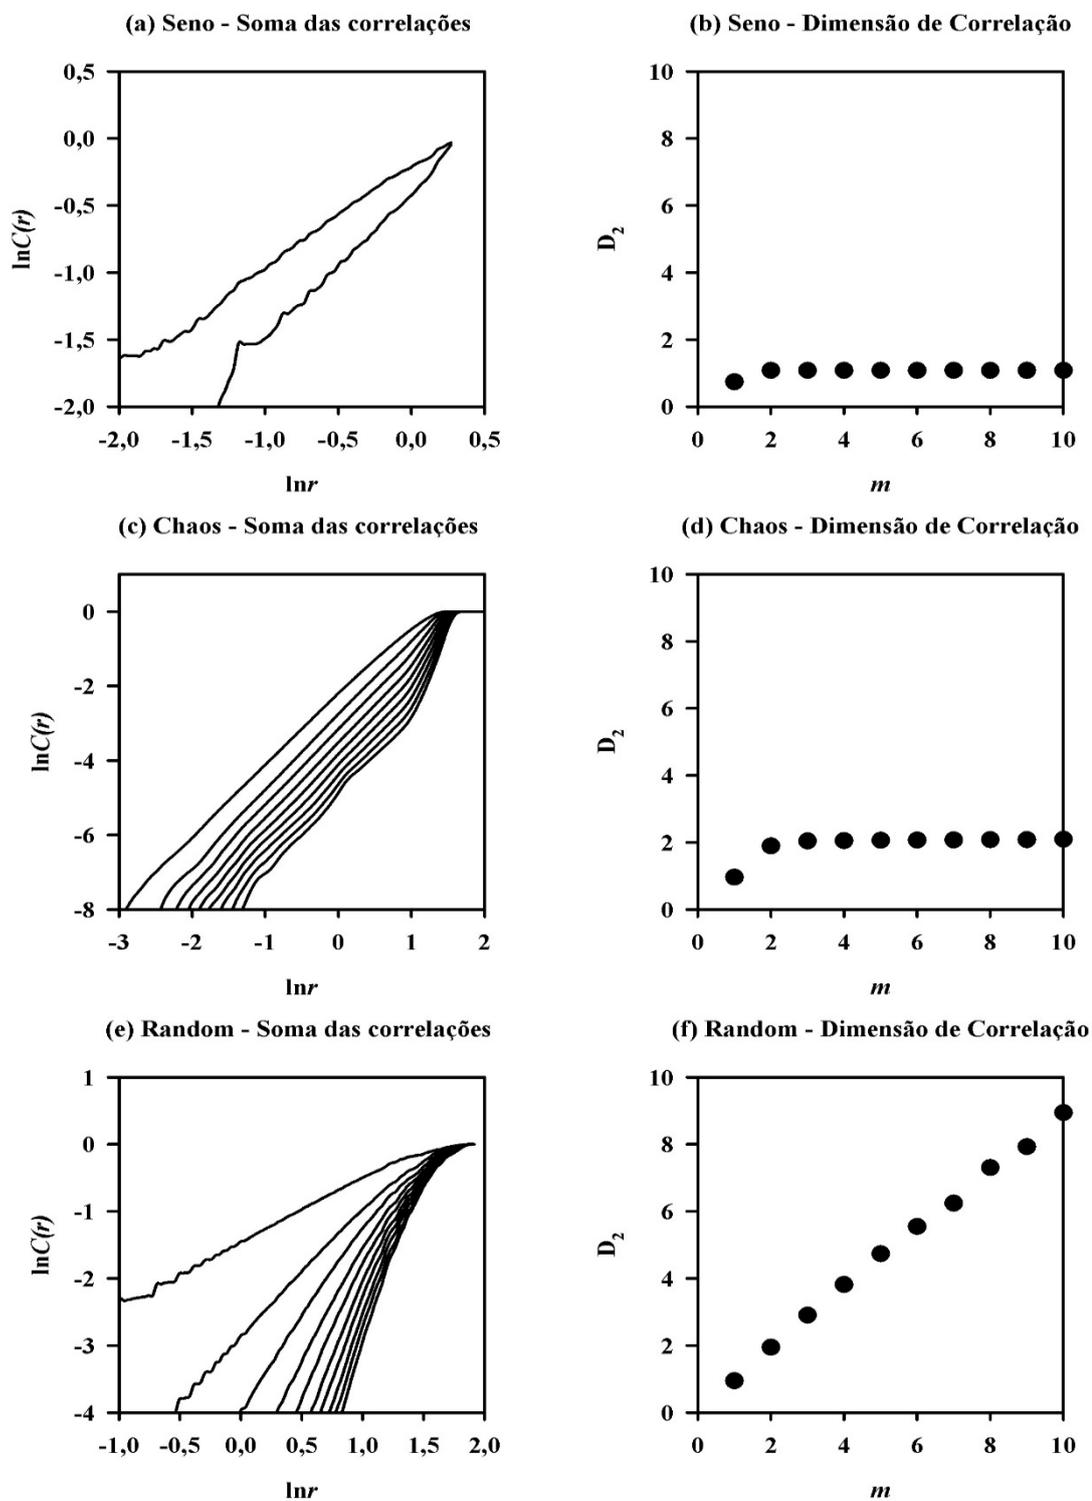


Figura 17. A esquerda $\ln C(r)$ vs $\ln r$ para valores crescentes de m , e a direita saturação da dimensão de correlação D_2 versus dimensão de imersão m para o atrator reconstruído a partir das variáveis teóricas.

A distinção entre baixa dimensionalidade (talvez determinismo) e alta dimensionalidade (talvez estocasticidade) é feita plotando-se a declinação de $\ln C(\varepsilon)$ por $\ln \varepsilon$, para espaços de fase m com dimensões cada vez maiores. Se D_2 satura depois de certo valor m e a saturação é baixa, então o sistema é geralmente considerado como exibindo dinâmica de baixa dimensão e possivelmente determinista. O valor da saturação é definido como a Dimensão de Correlação D_2 do atrator, e o número inteiro mais próximo acima deste valor é uma indicação do número de variáveis que regem predominantemente a dinâmica (WEBBER & ZBILUT, 2005; KYOUNG et al., 2011); em outras palavras, D_2 fornece número mínimo de equações diferenciais não lineares necessárias para descrever o atrator (MOON, 2004; CAMPANHARO, 2008). Por outro lado, se m aumenta sem limite, o sistema sob investigação geralmente exibe um comportamento de alta dimensão e possivelmente estocástico.

2.5. PREDIÇÃO NÃO LINEAR E VERIFICAÇÃO DO MODELO

O modelo de predição utilizado neste trabalho, a Predição Não Linear Simples, parte de uma série temporal escalar (passado) com objetivo determinar uma estimativa para os seus valores seguintes (futuro), sem que se conheçam as equações de governo do fenômeno físico associado ao sistema (SAVI, 2006). Um dos aspectos interessantes desse método é a possibilidade de se fazer previsões sem a construção explícita de um modelo para uma série temporal específica.

A seguir são apresentados os parâmetros que envolvem a predição, tais como o tempo máximo de previsão confiável ξ e os aspectos do método da Predição Não Linear Simples.

2.5.1. Tempo Máximo de Previsão Confiável ξ

O Expoente de Lyapunov λ_{max} é uma quantificação do “efeito borboleta” de Lorenz (1963) (FERREIRA, 2009). Logo, o tempo máximo de previsão confiável ξ

(também chamado “tempo de Lyapunov”), justifica-se a partir dos seguintes pressupostos:

Se o atrator não possui nenhum expoente λ_{max} positivo para as m -dimensões do espaço de fase, ou seja, $\lambda_{max} \leq 0$, então o sistema não é caótico; e desta forma uma pequena perturbação em uma órbita fará com que ela fique próxima desta ou haja tendência exponencial para a bacia de atração.

Se o atrator possui pelo menos um $\lambda_{max} > 0$, então o crescimento das perturbações é controlado por λ_{max} o que impele uma divergência exponencial das trajetórias.

Isto introduz uma maneira quantitativa de estimar a previsibilidade do sistema. Assim o tempo máximo de previsão confiável ξ é definido como:

$$\xi = \frac{\tau}{\lambda_{max}} \quad \text{Eq. 18}$$

onde τ representa aqui o intervalo da amostra experimental, λ_{max} o maior expoente de Lyapunov e o parâmetro ξ representa o tempo máximo de uma previsão confiável. Este conceito tem sido usado recentemente dentro da perspectiva climática (TSONIS, 2001; GOMES & VARRIALE, 2004; CHAUDHURI, 2006; MILLÁN et al., 2009).

2.5.2. Predição Não Linear Simples

Uma forma adequada para modelagem e que leva em conta a não linearidade usando séries temporais conhecidas do sistema estudado é a Predição Não Linear Simples, um método baseado na reconstrução do espaço de fase. Ele parte de uma série temporal conhecida, chamada Medida S_n com $n = 1, \dots, N$, para estimar valores futuros, S_{n+p} com $n = N + 1, \dots, N + p$, chamada Predita. Este modelo estabelece uma forma para estimar séries futuras. Na Figura 18 mais abaixo é possível observar um esquema que se relaciona ao problema de predição. Assim como afirmam Pinto & Savi (2003), Savi (2006), Viola et al. (2010), o processo de verificação pode ser realizado utilizando partes conhecidas da série temporal, de forma que se estabelece uma comparação entre os valores estimados com os valores futuros e os valores da série original.

As técnicas de predição classificam-se, de forma geral, em métodos lineares e não lineares, e ainda, globais e locais. Os principais aspectos relacionados à análise de séries temporais e predição não linear são discutidos e aprofundados em Casdagli (1989), Weigend & Gershenfeld (1994), Schreiber (1999), Kantz & Schreiber (2004), Savi (2006) e Abarbanel (2006).

Após a reconstrução do espaço de fase adequado para o desdobramento do atrator, define-se o raio de sondagem da hipersfera ε que está relacionado com o tamanho da vizinhança v_n em torno do ponto u_n , para realizar a predição em um instante de tempo Δn ($\Delta n = 1, \dots, p$) a frente de N .

Portanto, para todos os pontos u_n fechados dentro do raio ε da vizinhança v_n encontram-se os pontos de S_n (termos da série temporal) e suas respectivas predições $S_{n+\Delta n}$. A predição $P_{N+\Delta n}$ é então calculada a partir da média aritmética das predições individuais $S_{n+\Delta n}$. A equação de predição se apresenta da seguinte forma:

$$P_{n+\Delta n} = \frac{1}{|v_\varepsilon(u_N)|} \sum_{u_n \in v_\varepsilon(u_N)} S_{n+\Delta n} \quad \text{Eq. 19}$$

onde $|v_\varepsilon(u_N)|$ é o número de elementos pertencentes à vizinhança $v_\varepsilon(u_N)$. Isto também pode ser interpretado como sendo a média dos “futuros” dos vizinhos (KANTZ & SCHREIBER, 2004; VIOLA et al., 2010) (Figura 18).

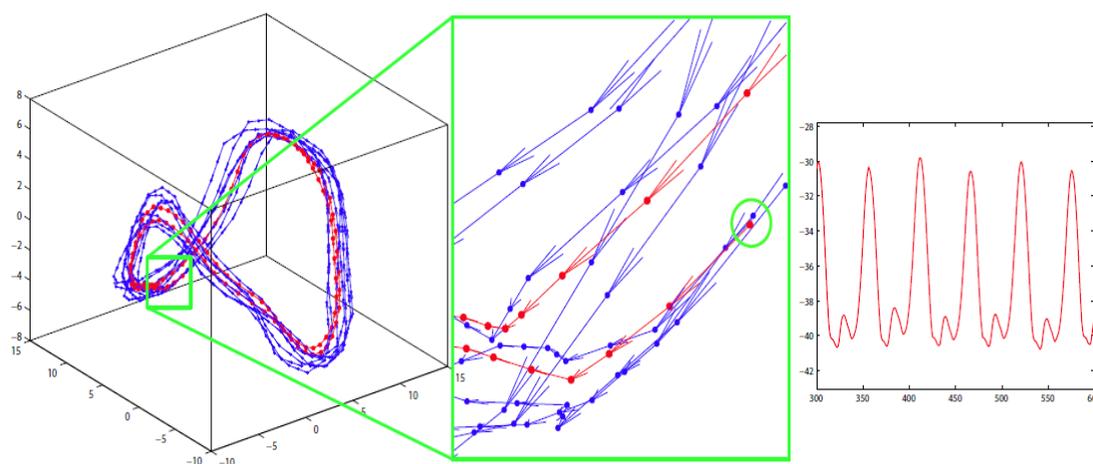


Figura 18. Esquema da Predição Não Linear Simples. Reconstrói-se o atrator a partir de uma série temporal medida, e busca-se a média do futuro dos estados vizinhos. Desses estados futuros é extraída a série temporal predita (figura adaptada de BASHARAT & SHAH, 2009).

Robusto e simples, esse método parte de um espaço de fase reconstruído em que todos os vizinhos são sondados dentro de um limiar auto-regressivo (do inglês Threshold Autoregressive TAR) para prever as medidas no tempo $N + P$ (TONG, 1983; 2007; 2011; 2012); e classifica-se em previsão local no sentido de que são utilizados termos de uma vizinhança de raio ε em torno de u_N e não se considera todo o espaço de fase (SAVI, 2006).

Maiores aprofundamentos sobre as técnicas apresentadas neste trabalho podem ser encontradas em Kantz & Schreiber (2004).

3. MATERIAL E MÉTODOS

Neste capítulo descreve-se o sítio experimental juntamente com os instrumentos, o período e a forma da coleta de dados; bem como os métodos (algoritmos) de análise e predição de séries temporais não lineares.

3.1. LOCALIZAÇÃO E INSTRUMENTOS

O sítio experimental localiza-se na Reserva Particular do Patrimônio Natural - RPPN SESC – Pantanal, município de Barão de Melgaço – MT, distante 160 km de Cuiabá, Mato Grosso, na região Centro-Oeste do Brasil, onde está instalada uma torre micrometeorológica de 32 m de altura (16°39'50''S; 56°47'50''O; 120 m) (Figura 19). Esta área apresenta uma floresta monodominante de Cambará (*Vochysia divergens*), conhecida localmente como cambarazal, com altura do dossel variando entre 28 a 30 m (ARIEIRA & NUNES DA CUNHA, 2006). O solo é classificado como GLEISSOLO HÁPLICO Ta Distrófico. O clima é Aw segundo a classificação de Köppen, cuja média anual de temperatura do ar é de 25,6 °C e a umidade relativa do ar é de 73,1%, precipitação média anual é de 1342 mm, com precipitação inferior a 15 mm no período seco (junho a agosto) e estação chuvosa com 97% da precipitação acumulada anual (BIUDES et al., 2009; INMET, 2009). Frequentemente

a inundaç o ocorre entre dezembro e maro (0,6 – 1,5 m de altura) caracterizando a fase aqu tica do Pantanal, que acompanha a estao chuvosa e a oscilao anual do n vel d' gua do rio Cuiab , sendo altamente influenciada pela precipitao local (NUNES DA CUNHA & JUNK, 2004; ARIEIRA & NUNES DA CUNHA, 2006).

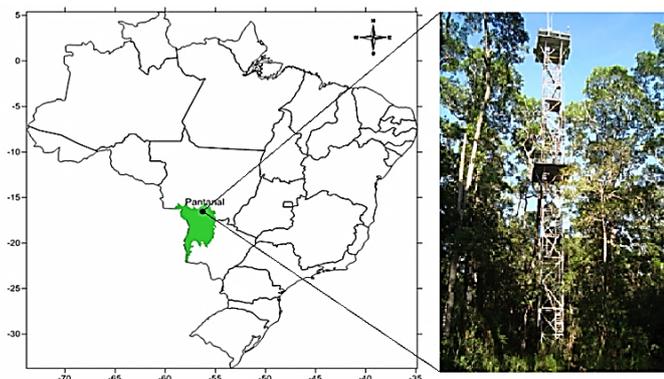


Figura 19. Mapa do Brasil, com destaque para o Pantanal Brasileiro, localizao da  rea de vegetao monodominante de Cambar  na RPPN SESC e da torre micrometeorol gica.

A instrumentao utilizada para a coleta de dados de saldo de radiao (R_n) foi um Net Radiometer, Kipp & Zonen Delft, Inc., Holland; para a temperatura (T) e umidade relativa (R_h) um termohigr metro (HMP 45 C, Vaisala, Inc., Helsinki, Finland) instalados a 37,7 m. Os dados foram processados e armazenados por dataloggers (CR 10X, Campbell Scientific, Inc., Ogden, Utah, USA). Para aumentar o n mero de canais de entrada no registrador foi utilizada uma placa multiplexadora (AM16/32A-ST-SW, Campbell Scientific, Inc., Ogden, Utah, USA).

Os dados utilizados neste trabalho foram amostrados a cada 10 segundos com extrao de m dias a cada 15 minutos, no per odo compreendido de 1  de setembro de 2006 at  1  de setembro de 2010.

3.2. AN LISE E PREDIO DE S RIES TEMPORAIS N O LINEARES

Analisou-se tr s s ries temporais experimentais micrometeorol gicas: do saldo de radiao (R_n), da temperatura do ar (T) e da umidade relativa (R_h) coletadas no s tio experimental.

O programa `surrogates.exe` do pacote de software TISEAN – Nonlinear Time Series Analysis (software de dom nio p blico dispon vel em <http://www.mpipks->

dresden.mpg.de/~tisean/) foi utilizado para testar a não linearidade das séries temporais utilizadas.

Os cálculos dos parâmetros necessários para a reconstrução dos atratores das séries temporais, Informação Mutua MI para a escolha do tempo de defasagem τ e Falsos Vizinhos Próximos FNN para a escolha da melhor dimensão de imersão m , assim como as análises das séries temporais não lineares, no que diz respeito aos seus aspectos qualitativos estimados pelos Gráficos de Recorrência RP , e quanto aos aspectos quantitativos pelas ferramentas de Análise de Quantificação de Recorrência RQA , foram feitos com a caixa de ferramentas TOCSY – Toolbox for Complex Systems for Matlab®, do Potsdam Institute for Climate Impact Research (PIK) (software de domínio público disponível em <http://tocsy.agnld.uni-potsdam.de>, disponível em <http://tocsy.agnld.uni-potsdam.de> acesso em 27/04/2011).

Ainda, as análises das séries temporais não lineares, no que diz respeito aos aspectos dinâmicos da divergência das órbitas dos atratores que é dado pelo Expoente de Lyapunov λ , e quanto aos aspectos geométricos dos atratores dado pela Dimensão de Correlação D_2 , foram calculados respectivamente pelo programa `lyap_r.exe` e pelo programa `d2.exe` do pacote de software TISEAN – Nonlinear Time Series Analysis.

As previsões das séries temporais não lineares foram feitas com o programa `zeroth.exe` do pacote de software TISEAN – Nonlinear Time Series Analysis.

Os cálculos dos erros das previsões foram feitos utilizando o software livre para uso não comercial IRENE – Integrated Resources for Evaluating Numerical Estimates, que é ferramenta de análise de dados com amplos recursos estatísticos voltados às técnicas de avaliação de modelos.

3.2.1. Medidas de Erro de Predição

A maneira de avaliar a distância entre os valores das séries temporais medidas e os valores das séries temporais previstas é através das medidas dos erros de predição (SAVI, 2006). Para este trabalho foram adotadas quatro medidas para quantificar o erro na predição, sendo elas: o Coeficiente de Correlação r , o coeficiente de

Willmott d , a Raiz Quadrada do Erro Médio RMSE e o Erro Médio Absoluto MAE , descritas a seguir.

A precisão de uma predição é dada pelo Coeficiente de Correlação r . Este índice estatístico indica o grau de associação entre duas grandezas, no caso deste trabalho, entre a série temporal medida (M) e série temporal predita (P). O Coeficiente de Correlação r é dado pela equação:

$$r = \frac{\sum_{i=1}^N (M - \bar{M})(P - \bar{P})}{\sqrt{[\sum_{i=1}^N (M - \bar{M})^2][\sum_{i=1}^N (P - \bar{P})^2]}} \quad \text{Eq. 20}$$

De modo que, o grau máximo de associação é que $r = 1$ significa uma correlação perfeita positiva entre as duas séries temporais, $r = -1$ significa uma correlação negativa perfeita entre as duas séries, isto é, se uma aumenta a outra diminui, e $r = 0$ que as séries não possuem associação uma com a outra.

A concordância se refere à exatidão ou à aproximação das séries temporais preditas às medidas. Para quantificar matematicamente essa aproximação, foi desenvolvido por Willmott (1982) um coeficiente designado concordância ou exatidão d . Seus valores variam de $d = 0$, para nenhuma concordância, a $d = 1$ para a concordância perfeita. O índice é dado pela equação abaixo:

$$d = 1 - \left[\frac{\sum_{i=1}^N (P - M)^2}{\sum_{i=1}^N (|P - \bar{M}| + |M - \bar{M}|)^2} \right] \quad \text{Eq. 21}$$

A Raiz Quadrada do Erro Médio RMSE é uma das estatísticas mais comuns de medição de erro, definida como:

$$RMSE = \sqrt{\frac{1}{p} \sum_{n=N+1}^{N+p} (M_n - P_n)^2} \quad \text{Eq. 22}$$

O Erro Médio Absoluto MAE é a quantidade usada para medir o quão próximas estão os dados previstos dos dados medidos. O MAE é dado pela equação:

$$MAE = \frac{1}{N} \sum_{i=1}^N |P - M| \quad \text{Eq. 23}$$

4. RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados e discussão das análises que constituem a parametrização necessária para a modelagem por teoria dos sistemas dinâmicos utilizada neste trabalho. Os resultados iniciam pela descrição microclimática das séries temporais medidas na área de estudo. Em seguida são aplicados testes de não linearidade nas séries temporais medidas e reconstruído o espaço de fase m -dimensional no qual são imersos o conjunto atrator da dinâmica de cada série temporal. Providos de um atrator, são feitas análises qualitativas e quantitativas da sua dinâmica para estimar os parâmetros necessários ao modelo quanto às suas especificidades. Por fim, e como propósito principal deste trabalho, são apresentadas as séries temporais modeladas por predição não linear simples e os erros de predição em termos de comparação com as séries temporais medidas.

4.1. DESCRIÇÃO MICROCLIMÁTICA

Nesta Seção é feita a descrição micrometeorológica da área de estudo em termos das variáveis medidas e da sazonalidade (Tabela 1). O saldo de radiação foi significativamente afetado pelas estações do ano. O saldo de radiação teve maior média \pm desvio padrão durante a estação chuvosa ($11,37 \pm 4,06 \text{ MJm}^{-2} \text{ dia}^{-1}$) que durante a estação seca ($7,40 \pm 1,97 \text{ MJm}^{-2} \text{ dia}^{-1}$). Essa diferença é esperada devido ao

fator astronômico, pois a estação chuvosa ocorre no período de maior incidência de radiação solar no hemisfério sul.

Tabela 1. Média mensal e estacional e desvio padrão mensal e estacional do saldo de radiação (*Rn*), da temperatura do ar (*T*) e da umidade relativa (*Rh*).

Variável/mês	<i>Rn</i> ($MJm^{-2}dia^{-1}$)	<i>T</i> ($^{\circ}C$)	<i>Rh</i> (%)
Janeiro	13,10±3,95	26,57±1,39	80,79±8,10
Fevereiro	12,98±4,22	26,82±1,32	82,21±5,51
Março	12,65±3,71	27,32±1,40	81,30±5,54
Abril	10,44±2,88	26,62±1,97	79,48±6,58
Mai	7,85±2,32	23,64±3,61	76,45±7,81
Junho	6,65±1,41	22,92±3,09	71,69±9,96
Julho	6,85±1,87	23,42±4,04	61,44±12,49
Agosto	8,65±1,88	25,02±3,66	54,02±14,24
Setembro	9,19±3,05	26,43±3,63	57,33±13,85
Outubro	10,88±4,11	27,08±2,14	71,67±10,10
Novembro	12,70±3,84	27,09±1,81	75,21±9,22
Dezembro	12,57±4,15	26,42±1,35	80,69±8,39
Anual	10,37±4,04	25,78±3,07	72,63±13,73
Seca	7,40±1,97	23,79±3,73	62,27±14,35
Chuva	11,37±4,06	26,79±2,49	76,13±11,38

A temperatura do ar foi significativamente afetada pelas estações do ano. As médias mensais da temperatura \pm desvio padrão foram maiores durante a estação chuvosa ($26,79\pm2,49^{\circ}C$) que estação seca ($23,79\pm3,73^{\circ}C$). Os maiores valores das temperaturas médias durante a estação chuvosa estão relacionados com a maior disponibilidade de energia radiante. A redução nos valores da temperatura do ar na estação seca, além da menor disponibilidade de energia radiante, pode ter sido resultado da ocorrência de frentes frias. Nestas situações de eventos de frentes frias, ocorrem quedas bruscas da radiação incidente, devido à presença de nebulosidade. Durante esses eventos, a temperatura máxima pode ser $10^{\circ}C$ mais baixa que a máxima temperatura do dia anterior. Além disso, dependendo do volume de ar frio, a temperatura pode demorar de 2 a 3 dias para retornar aos valores registrados antes da passagem da frente fria (FISCH, 1996; BIUDES et al., 2012)

A umidade relativa do ar foi significativamente afetada pelas estações do ano. As médias mensais da umidade relativa \pm desvio padrão foram maiores durante a estação chuvosa ($76,13 \pm 11,38\%$) do que na estação seca ($62,27 \pm 14,35\%$). O aumento da umidade relativa do ar na estação chuvosa foi resultado da maior presença de vapor d'água no ar, associado à maior precipitação (ALVES et al., 1999, BIUDES et al., 2012). Os menores valores de umidade relativa do ar na estação seca estão relacionados com a menor disponibilidade de água no solo, o que causa diminuição na evapotranspiração e conseqüentemente no fluxo de calor latente (WRIGHT et al., 1996; BIUDES et al., 2009; BIUDES et al., 2012).

A Figura 20 ilustra, a partir de médias mensais de setembro de 2006 até agosto de 2010, o padrão semelhante de variabilidade sazonal das variáveis. Destacam-se as menores médias de R_n em junho e julho, e as maiores de novembro à março. A T também exibiu os menores valores em junho e julho, e os maiores valores de setembro até abril. Por fim a R_h exibiu os menores valores nos período mais distante da estação chuvosa, ou seja, julho, agosto e setembro.

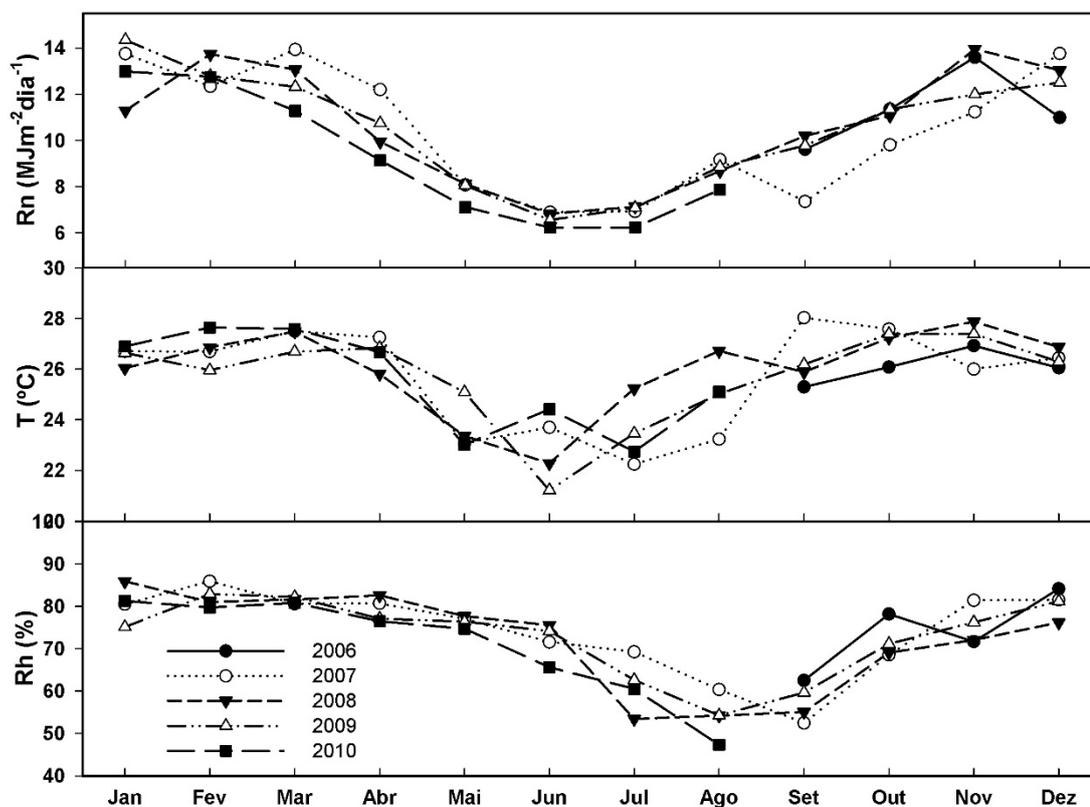


Figura 20. Média mensal do saldo de radiação (R_n), da temperatura do ar (T) e da umidade relativa (R_h).

Os valores maiores das médias da temperatura do ar e umidade relativa na estação chuvosa também são devidos ao efeito liberador/moderador do termo de armazenamento de energia da biomassa, ou seja, durante a noite, a liberação de energia pela biomassa da floresta age no sentido de manter o balanço radioativo noturno e não permite resfriamento acentuado da superfície (FISCH, 1996; BIUDES et al., 2012).

A precipitação neste período, segundo Biudes et al. (2013), foi significativamente afetada pelas estações do ano, com menores valores durante a estação seca refletindo 6 % e maiores valores na estação chuvosa com 94% do total precipitado.

4.2. TESTE DE NÃO LINEARIDADE

Como justificativa para a abordagem por teoria dos sistemas dinâmicos foi aplicado o teste Surrogate nos dados antes da análise e da predição (SCHREIBER & SCHMITZ, 1996; SCHREIBER, 1999; MILLÁN et al., 2009). Os resultados da aplicação do teste Surrogate (Tabela 2) são apresentados em termos de número de interações e relativa discrepância entre a série temporal original e o conjunto de dados substitutos (Surrogate). Admitiu-se a hipótese nula como sendo que a série temporal foi gerada por um processo estacionário estocástico gaussiano, e a rejeitou-se ao nível de significância determinado ($p < 0,05$) de forma que a estrutura não linear e seus invariantes topológicos ainda estão preservados no Surrogate (SCHREIBER & SCHMITZ, 2000).

Tabela 2. Parâmetros para a construção das séries Surrogate.

Variáveis Microclimáticas	Nº de Interações	Discrepância Relativa
Rn	766	0,2
T	32	0,0029
Rh	204	0,0093

As séries temporais das variáveis Rn e a $Rn_{(SUR)}$ apresentaram os maiores valores de número de interações e de discrepância relativa. Muito possivelmente isto se deve ao fato de que o saldo de radiação ser extremamente sensível à qualquer

variação de outras variáveis microclimatológicas, tais como nebulosidade ou chuva, cobertura do solo e umidade do solo, cobertura do dossel; à sazonalidade; de maneira que mesmo derivando de uma forçante linear como radiação solar, esses aspectos tornam o Rn uma dinâmica diurna extremamente não linear em determinados períodos do ano. Contudo, durante o período noturno, o Rn exibe uma dinâmica bem comportada com padrões que flutuam próximos de -50 W.m^2 durante quase toda a noite e durante quase todo o ano. Isto justifica fortemente, que embora a série tenha um expoente de Lyapunov positivo (conforme descrito na Seção 4.4.3), indicando caos durante o dia, também possua trechos com dinâmica comportada durante a noite.

4.3. RECONSTRUÇÃO DO ESPAÇO DE FASE

Os parâmetros necessários para a reconstrução do espaço de fase dos atratores, tempo de defasagem temporal τ (FRASER & SWINNEY, 1986; GOMES & VARRIALE, 2004; KANTZ & SCHREIBER, 2004; SAVI, 2006; MILLÁN et al., 2009; VIOLA et al., 2010) e dimensão de imersão m (KENNEL et al., 1992; KANTZ & SCHREIBER, 2004; SAVI, 2006; MILLÁN et al., 2009; VIOLA et al., 2010) foram calculados (Tabela 3) respectivamente pelo método da Informação Mútua $MI(\tau)$ (Figura 21) e pelo método dos Falsos Vizinhos Próximos FNN (Figura 22).

Tabela 3. Parâmetro para a reconstrução do espaço de fase.

Variáveis Microclimáticas	Defasagem Temporal τ	Dimensão de Imersão m
Rn	24	6
T	30	6
Rh	50	6

Para efeito de visualização é apresentada a Figura 23 contendo um recorte tridimensional dos atratores m -dimensionais reconstruídos a partir dos parâmetros da Tabela 3, com as séries temporais teóricas e também com as séries temporais medidas.

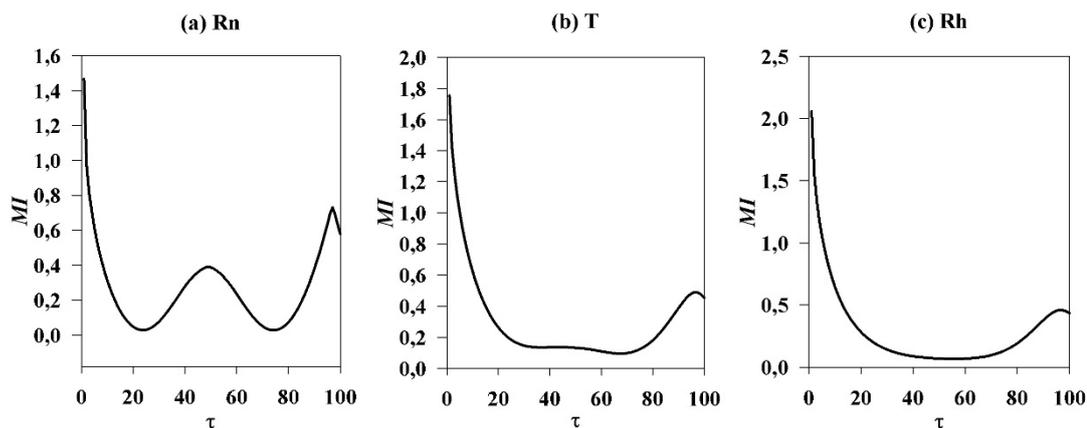


Figura 21. Informação Mutua MI para a escolha do tempo de defasagem τ .

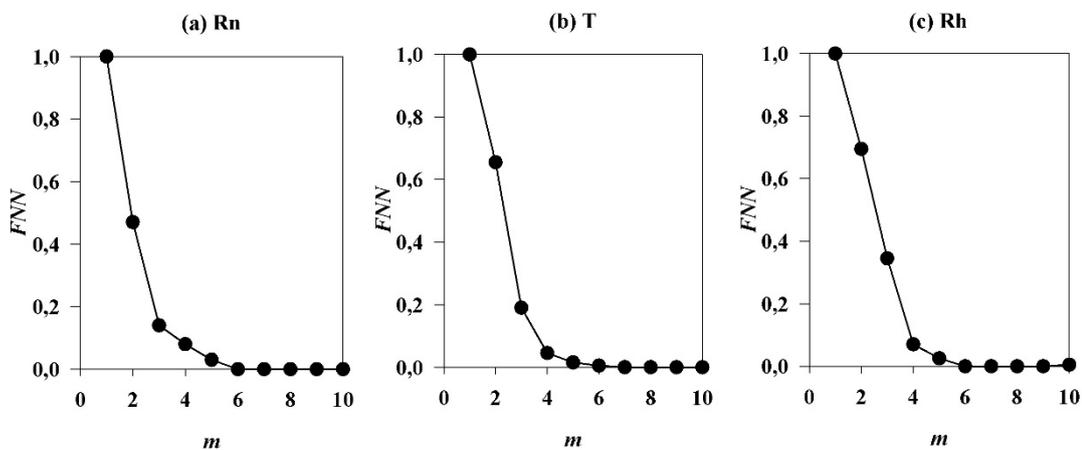


Figura 22. Falsos Vizinhos Próximos FNN para a escolha da melhor dimensão de imersão m .

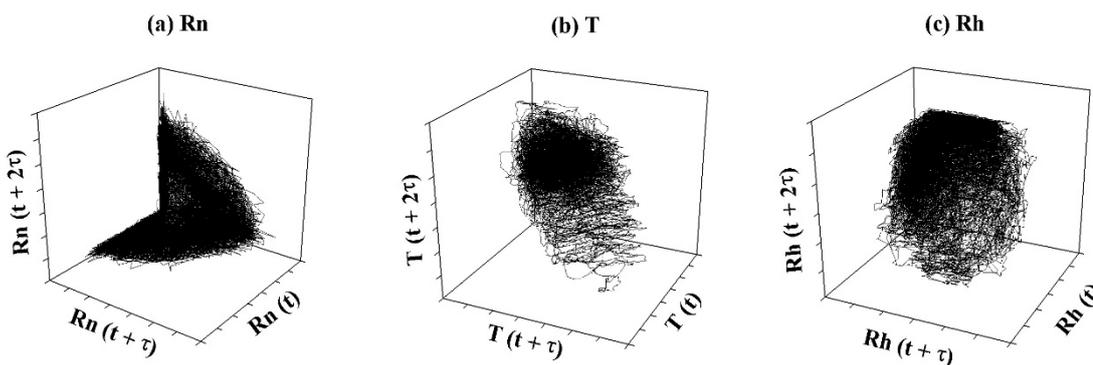


Figura 23. Reconstrução tridimensional dos atratores das variáveis microclimáticas.

A visualização de uma dinâmica de dimensões maiores em um recorte com dimensões menores do que a total é conhecido na literatura como seção de Poincaré (KANTZ & SCHREIBER, 2004). O recorte tridimensional do atrator reconstruído associado à série temporal Rn (Figura 23a) possibilita observar nuances da dinâmica,

que se apresenta achatada e com pontos de retorno bem definidos em determinadas regiões. Este retorno muito possivelmente seja devido às medidas do período noturno da série temporal, em que existe uma tendência a permanecer em torno de -50 W.m^{-2} . Quanto ao recorte tridimensional do atrator associado à série temporal T (Figura 23b) é possível observar uma densidade maior de estados com uma cauda de estados menos frequentes; as órbitas são atraídas para a grande densidade de pontos a qual pertencem as médias anuais de temperatura. Por fim, quanto ao recorte tridimensional do atrator associado à série temporal Rh (Figura 23c) é possível observar uma dinâmica parecida com a referida anteriormente (Figura 23b); no entanto, existe uma distribuição maior das órbitas por todo o espaço de fase.

Como a densidade de estados é alta devido à quantidade de dados e de difícil visualização, optou-se também em apresentar na Figura 24 os atratores reconstruídos de forma sazonal, ou seja, um mês do período seco (julho) e outro mês do período chuvoso (janeiro) de 2007.

Mesmo em um recorte tridimensional de uma dinâmica de seis dimensões a visualização da Figura 24 proporciona perceber como as trajetórias dos atratores possuem forte sazonalidade durante as estações seca (julho) e chuvosa (janeiro) e como essas variações sazonais possivelmente afetam a predição futura das órbitas do atrator, e conseqüentemente das séries temporais.

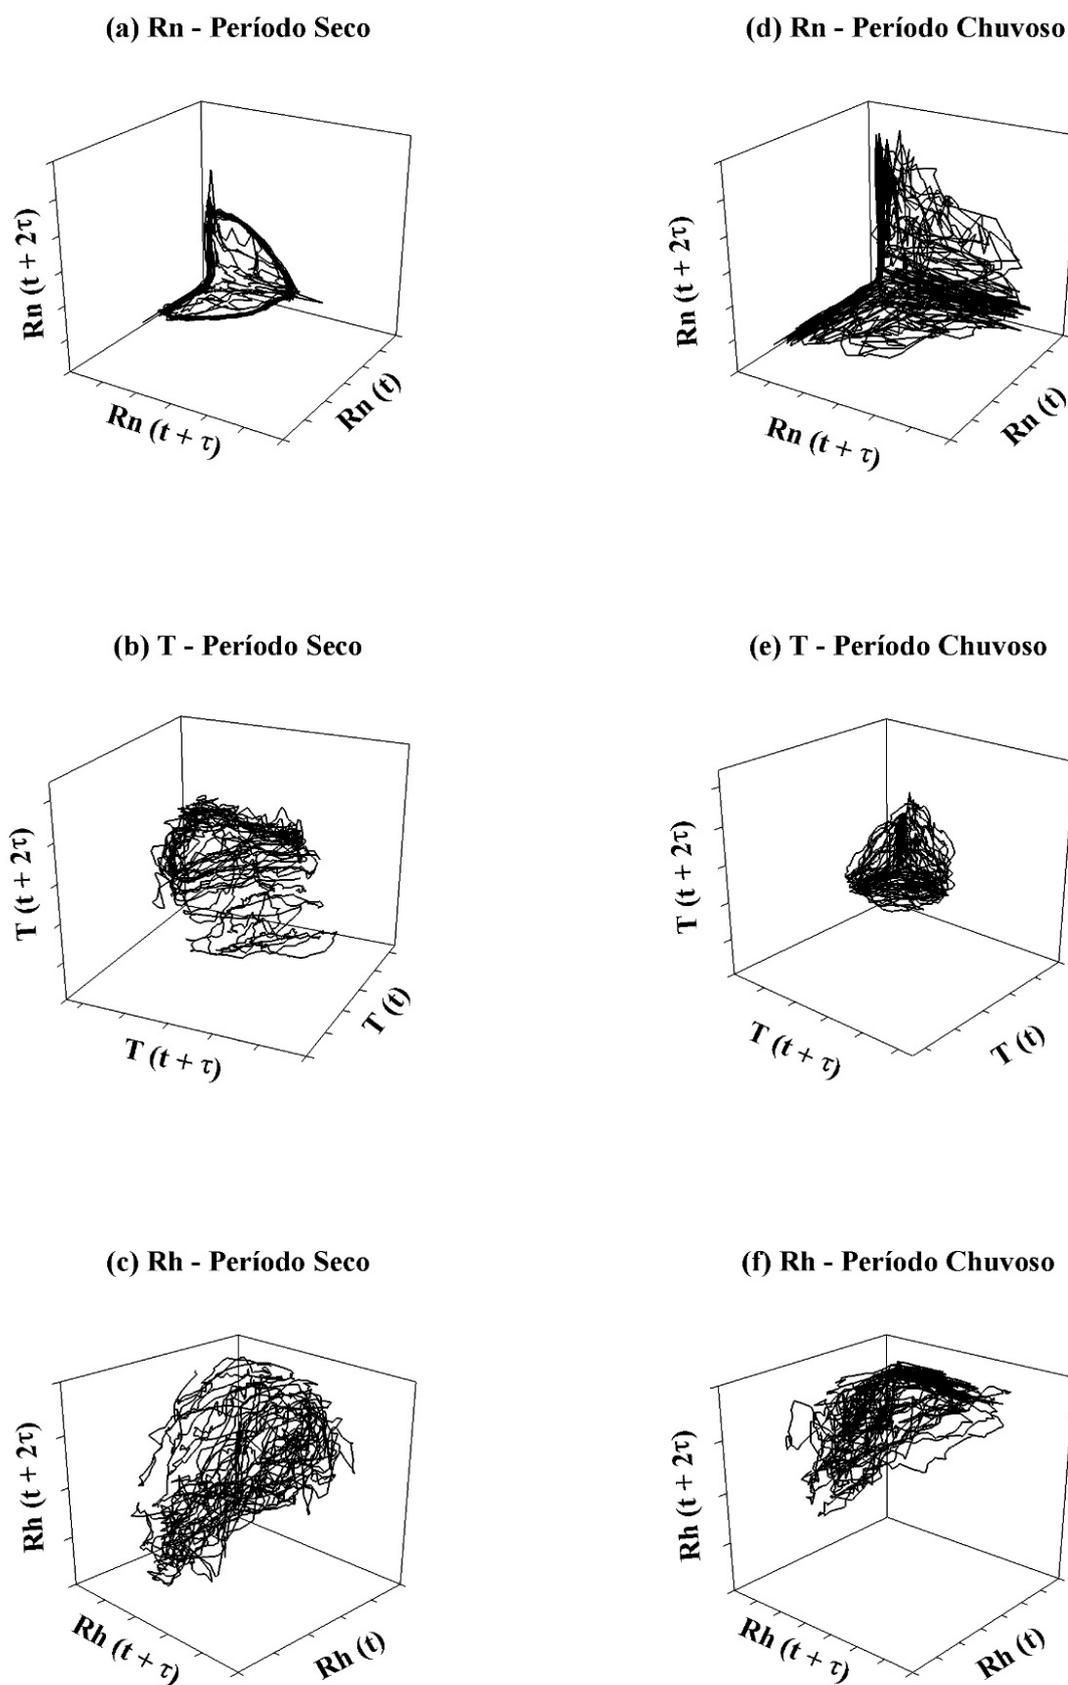


Figura 24. Reconstrução tridimensional dos atratores associados às variáveis microclimáticas com ênfase na sazonalidade utilizando janeiro para períodos chuvosos e julho para períodos secos.

Apresentado sazonalmente, os recortes tridimensionais do atrator associado à série temporal Rn para os meses de julho de 2007 (Figura 24a) e agosto de 2007 (Figura 24d) possibilitaram uma visualização da variação sazonal da dinâmica dos estados do sistema. No período seco (Figura 24a), a dinâmica se aproxima muito de um atrator ciclo limite, embora exiba no espaço de fase contornos dobrados que se aproximam de uma ferradura que se fecha nas extremidades referentes aos estados em horários noturnos com poucas variações de estados erráticos. No período chuvoso (Figura 24d) a estrutura que se apresenta plana também se dilata exibindo um preenchimento de estados bastante errático no seu interior. A partir disso é possível inferir que a dinâmica do período chuvoso para o atrator associado a série Rn é mais fácil de capturar na seca do que na chuva. As descrições acima são bastante características de sistemas dissipativos que apresentam expansão e contração do elemento de volume no espaço de fase (NICOLIS & PRIGOGINE, 1998; GOMES & VARRIALE, 2004; SAVI, 2006).

Os recortes tridimensionais do atrator associado à série temporal T para o período seco de julho de 2007 (Figura 24b) possibilitou visualizar uma estrutura em forma de *torus* (formato de um biscoito) com deslocamentos das órbitas para patamares inferiores no espaço de estados, que foram causados por entradas de frentes frias no sistema, que por sua vez dificultam as previsões. No período chuvoso (Figura 24e) houve uma contração da dinâmica, ocupando um volume menor no espaço de estados, fazendo com que as orbitas do recorte do atrator se apresentassem mais comportadas, mas ao mesmo tempo sobrepostas. Estas análises são de acordo com as variações nas amplitudes térmicas, que são maiores no período seco e menores no período chuvoso.

Por fim, quanto aos recortes tridimensionais do atrator associado à série temporal Rh para o período seco de julho de 2007 (Figura 24c) é possível visualizar uma estrutura errática ocupando um volume maior no espaço de estados e exibindo características de dinâmica pouco previsível, como é o caso de dinâmicas caóticas. No período chuvoso de janeiro de 2007 (Figura 24f) o recorte do atrator permite visualizar uma contração do volume formando uma estrutura plana aparentemente mais ordenada com estados próximos de um ciclo. Muito provavelmente isto se deve

aos valores da umidade relativa no período chuvoso que se mante aproximadamente próximos de 100% durante todo o período.

Os conhecimentos extraídos de forma qualitativa através das visualizações dos recortes tridimensionais dos atratores associados às séries temporais utilizando trechos sazonais trazem as primeiras informações quanto a dinâmica dos estados a serem preditos, de forma que é possível afirmar que as três variáveis estudadas nestes trabalho possuem comportamentos sazonalmente distintos umas das outras.

4.4. ANÁLISE DAS SÉRIES TEMPORAIS NÃO LINEARES

Nas próximas quatro seções são apresentados os resultados das análises de séries temporais não lineares fazendo uso de quatro ferramentas da Teoria dos Sistemas Dinâmicos, sendo elas: os Gráficos de Recorrência *RP*, a Análise de Quantificação de Recorrência *RQA*, o Expoente de Lyapunov λ e a Dimensão de Correlação D_2 .

4.4.1. Gráficos de Recorrência *RP*

O Gráfico de Recorrência *RP* é uma técnica avançada de análise de dados não lineares. Ele é uma visualização (ou um gráfico) de uma matriz quadrada, na qual os elementos da matriz correspondem aos momentos em que um determinado estado de um sistema dinâmico é recorrente. Tecnicamente, um *RP* revela todos os momentos em que a trajetória no espaço de fase do sistema dinâmico visita aproximadamente a mesma área no espaço de fase (MARWAN et al, 2007).

Segundo Eckmann et al. (1987) os *RP* apresentam duas características principais, sendo uma de grande escala chamada “tipologia” que são os resultados qualitativos apresentados nesta Seção, e uma de pequena escala chamada “textura” que são os resultados quantitativos (a *RQA*) apresentados na próxima Seção.

O objetivo inicial do *RP* é a inspeção visual das trajetórias no espaço de fase de dimensões superiores ($m > 3$). A visão de um *RP* provê indícios sobre a evolução temporal dessas trajetórias. São apresentados nas Figuras 25, 26 e 27 os *RP*

dos atratores associados às séries temporais das variáveis micrometeorológicas estudadas.

Nesses RP s foram destacados com uma linha a separação entre os anos, e em cinza os períodos secos de cada ano. Para a melhor identificação, os aspectos da descrição qualitativa da tipologia dos RP s foram destacados em vermelho e numerados.

Da série temporal microclimática Rn foi gerado o RP_{Rn} (Figura 25) que apresentou uma tipologia que oscilou sazonalmente entre periódica e aleatória. A inspeção visual do RP_{Rn} possibilita duas interpretações. Por um lado, observa-se uma recorrência periódica atribuída aos agrupamentos (clusters) em forma de xadrez e também aos espaços em branco indicadores de que a evolução dos estados do sistema foi semelhante em momentos diferentes, e ainda que alguns estados não mudam ou mudam muito lentamente durante o tempo, indicando comportamento laminar (Figura 25: destaque 1). Por outro lado, as observações de pontos isolados, que são representativos de estados raros, de forte flutuação do sistema, ou que não persistem por muito tempo indicam um comportamento aleatório (Figura 25: destaque 2). A visualização do RP_{Rn} como um todo possibilita identificar a duração dos agrupamentos em forma de xadrez, que ocorreram nos três meses do período seco em todos os anos analisados, respectivamente nos meses de junho, julho e agosto (Figura 25: destaque 1). Os meses de março, abril e maio, período em que o Pantanal encontra-se alagado, localizado temporalmente na separação entre os agrupamentos e os estados aleatórios, apresentou estruturas de linhas retas significando que os estados estão mudando lentamente e também linhas curvas e longas significando que a dinâmica do sistema está mudando (Figura 25: destaque 3). As regiões quase sem pontos são indicadoras de praticamente nenhuma recorrência, e aconteceram na intersecção das duas tipologias, ou seja, os meses junho, julho e agosto do período seco possuem uma recorrência praticamente nula em relação aos demais meses do ano, evidenciando a diferença sazonal do comportamento dinâmico do Rn (Figura 25: destaques 4 e 5).

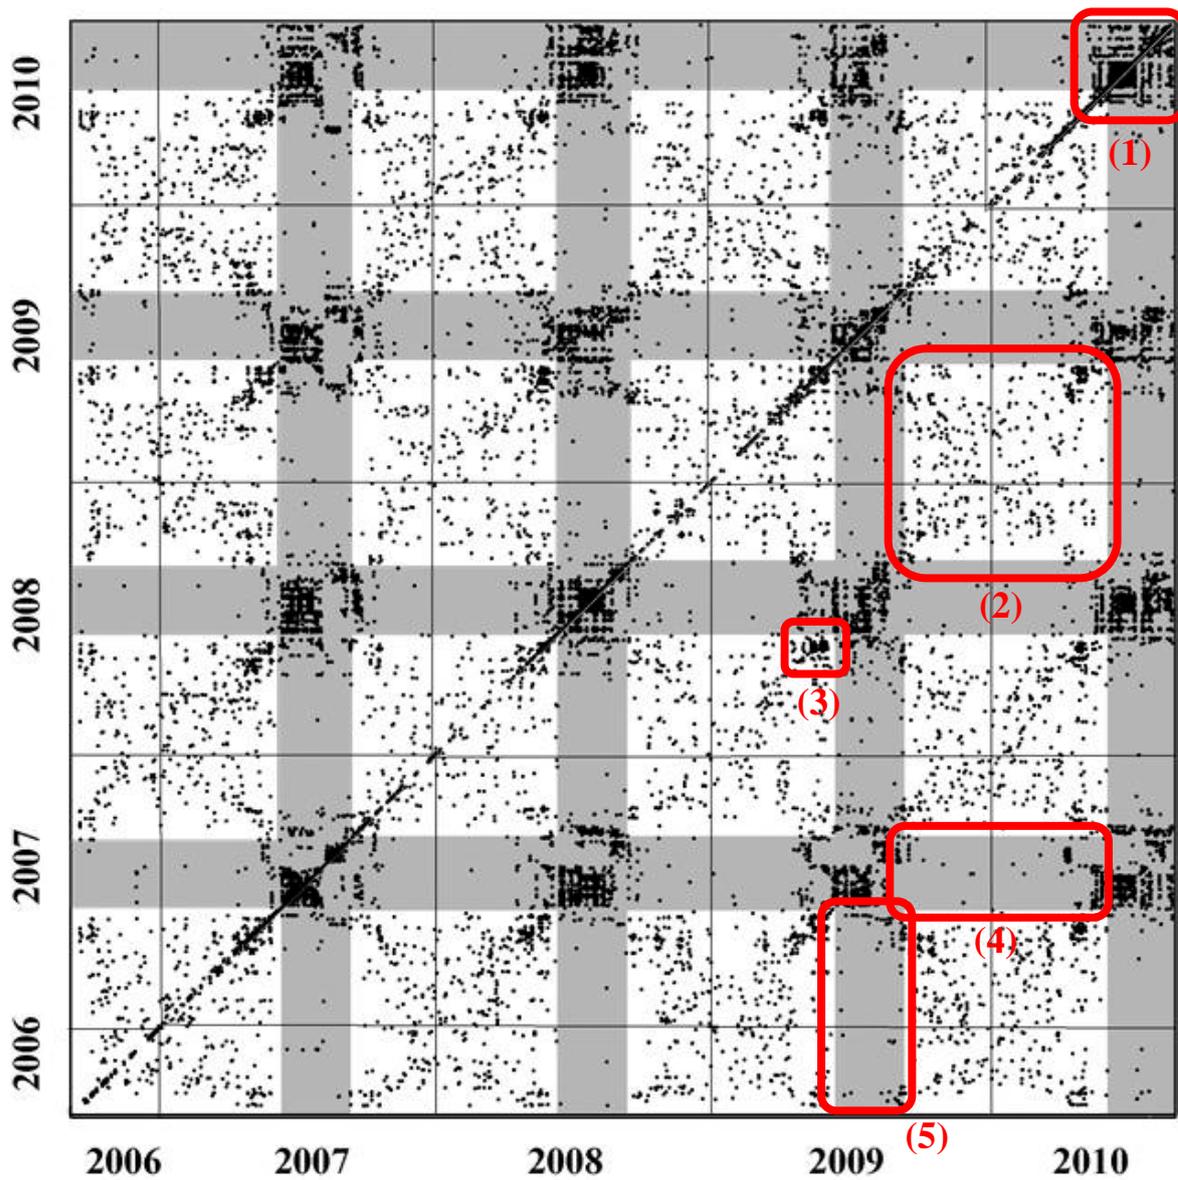


Figura 25. Gráficos de Recorrência RP da variável microclimática R_n .

A série temporal microclimática T foi utilizada para gerar o RP_T que apresentou uma tipologia padrão de sistemas quase-periódicos com transições de fase (Figura 26). Na inspeção visual do RP_T observa-se uma recorrência quase-periódica atribuída por possuir agrupamentos (clusters) em forma de xadrez nos dois períodos, o seco e o chuvoso (Figura 26: destaques 1 e 2). Nos períodos secos os agrupamentos são menores e nos períodos chuvosos os agrupamentos são maiores. Ainda sobre essas recorrências de estados (agrupamentos), eles não acontecem na intersecção entre os períodos secos e chuvosos do RP_T , de modo que espaços em branco preenchem predominantemente essas regiões juntamente com alguns pontos de estados raros (Figura 26: destaques 3 e 4). A interrupção entre os dois agrupamentos, os secos e os chuvosos, é preenchida com estruturas de linhas retas significando que os estados estão mudando muito lentamente (Figura 26: destaque 5) e também com linhas curvas e longas que significam a dinâmica do sistema está mudando (Figura 26: destaque 6). Disto infere-se que a sazonalidade da dinâmica da T , visto as diferentes recorrências características em cada período do ano, o seco e o chuvoso, deve ser considerada na previsão de séries temporais.

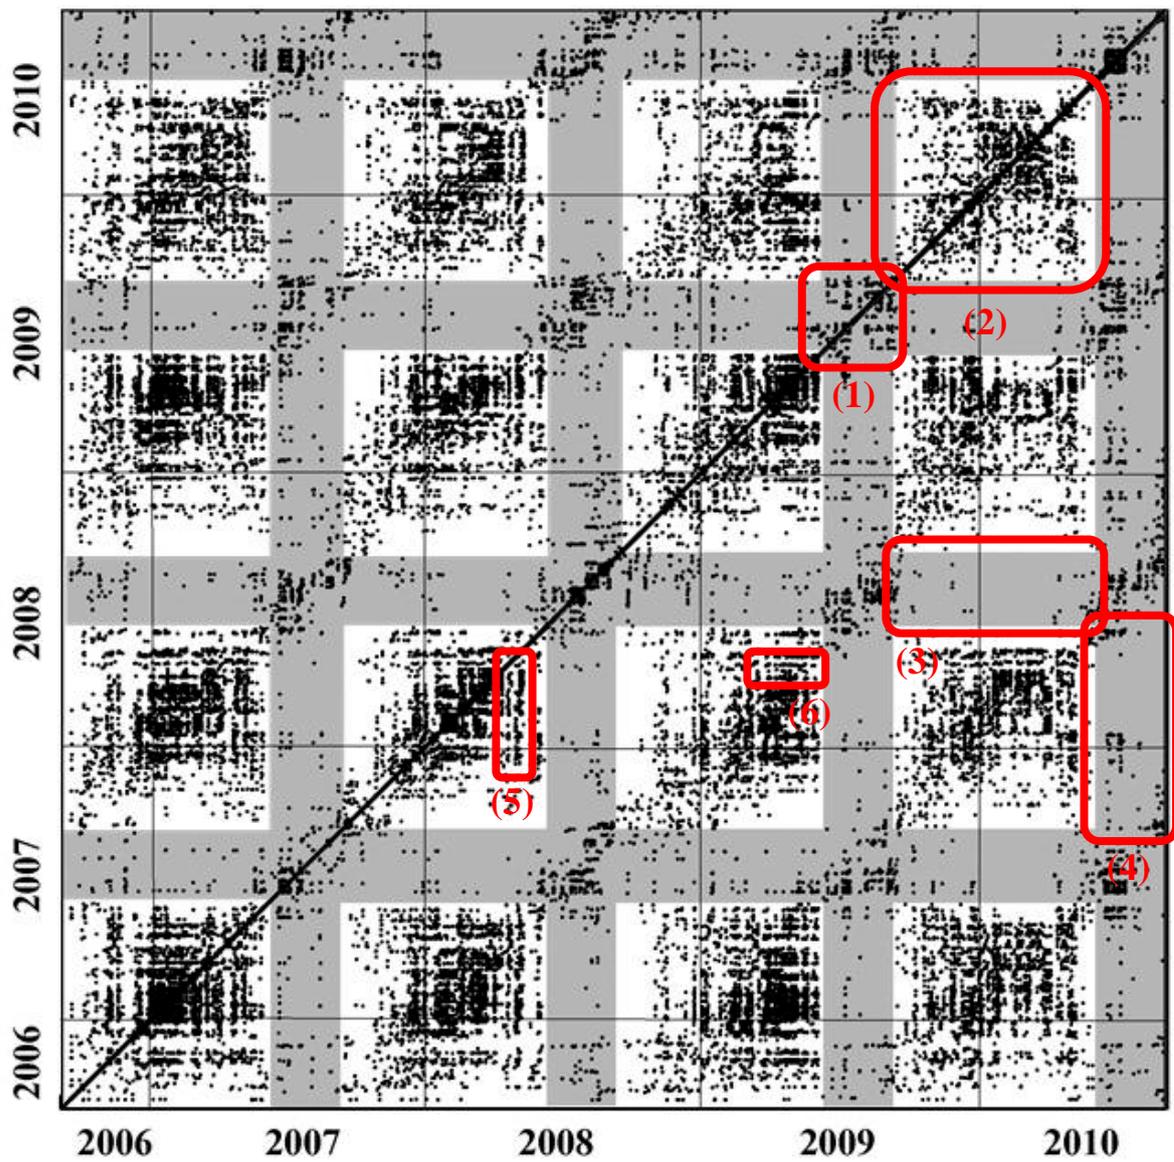


Figura 26. Gráficos de Recorrência RP da variável microclimática T .

O RP_{Rh} resultado da série temporal Rh apresentou uma tipologia padrão de sistemas quase-periódicos com transições de fase (Figura 27). A inspeção visual do RP_{Rh} permite observar uma recorrência quase periódica possuidora de grandes agrupamentos (clusters) em forma de xadrez que se iniciam no segundo mês do período chuvoso, no caso do mês de novembro, e perduram até o primeiro mês do período seco, o mês de junho (Figura 27: destaque 1). Entre esses agrupamentos do RP_{Rh} possuem defasagem de um a dois meses com relação aos períodos secos e chuvosos (Figura 27: destaque 2). A transição entre os agrupamentos e os espaços em branco é preenchida com estruturas de linhas retas significando que os estados estão mudando muito lentamente (Figura 27: destaques 3 e 4). Os espaços em branco com alguns pontos raros nos meses de julho, agosto, setembro e outubro possibilitam indicar que a Rh possui uma dinâmica com estados que não se repetem ou acontecem muito pouco tornando a previsão micrometeorológica um problema de difícil solução (Figura 27: destaques 5 e 6).

Os Gráficos de Recorrência RP são reconhecidos como uma ferramenta poderosa para a análise de dados, não somente para a visualização das estruturas da série temporal, mas também para estimar as suas invariantes topológicas. Através do RP uma grande quantidade de informação é codificada em uma representação bidimensional mostrando que sob algumas condições é possível reconstruir um atrator a partir do RP , pelo menos, topologicamente. Isto significa que todas as informações relevantes da dinâmica estão contidas na textura (THIEL et al., 2004).

Os resultados da textura dos RP através da Análise de Quantificação de Recorrência RQA serão apresentados na próxima Seção.

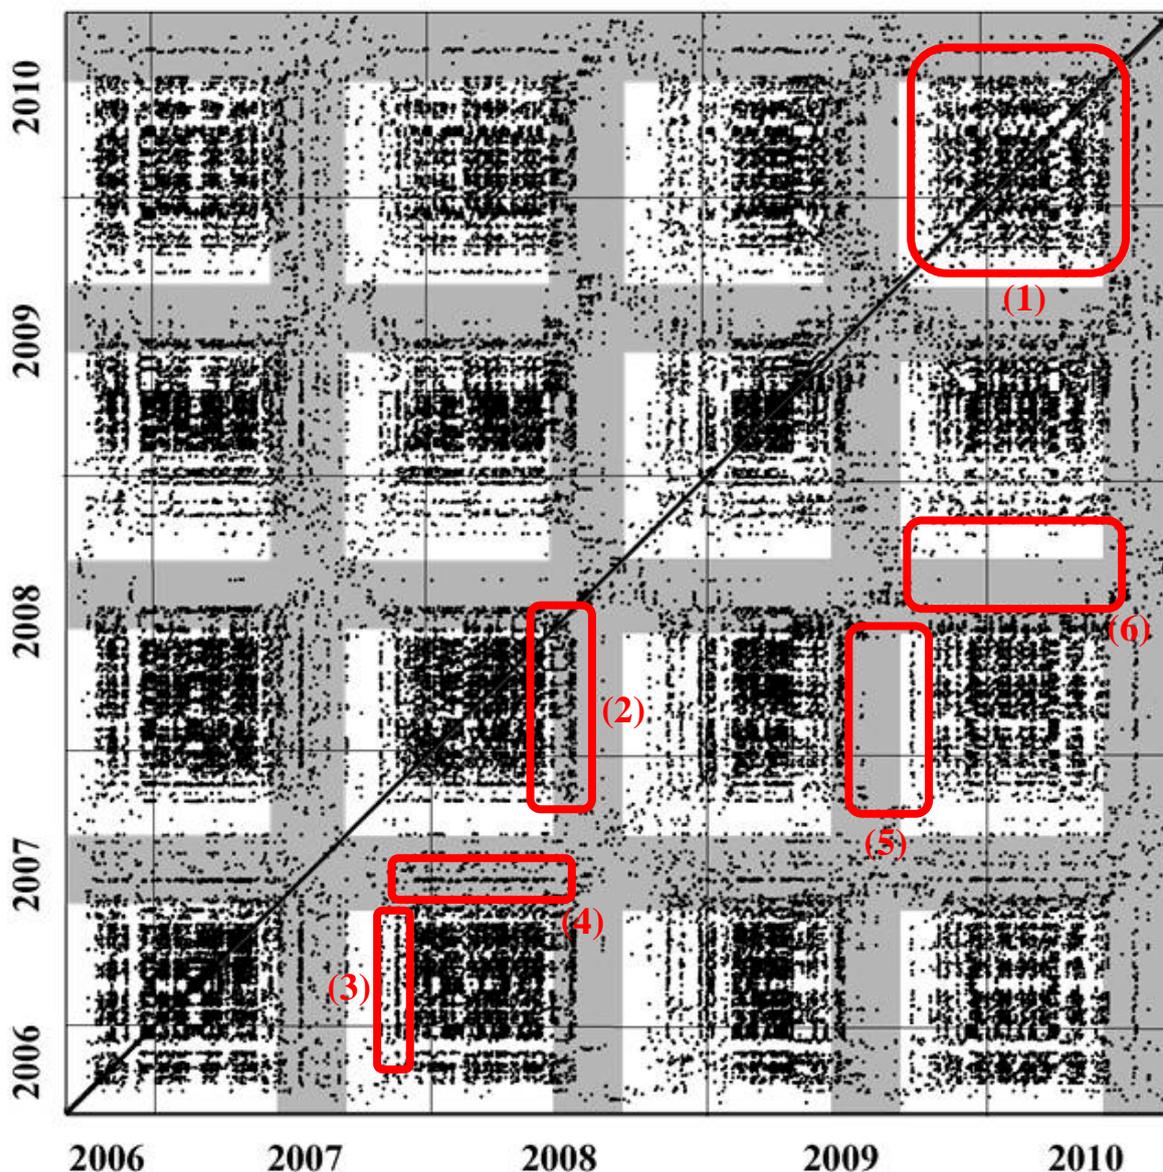


Figura 27. Gráficos de Recorrência RP da variável microclimática Rh .

4.4.2. Análise de Quantificação de Recorrência – RQA

A Análise de Quantificação de Recorrência RQA transforma as representações gráficas do RP em estatísticas (ZBILUT & WEBBER Jr., 1992; WEBBER Jr & ZBILUT, 1994; MARWAN et al., 2002). Apresentamos a seguir os resultados de quatro Análises Quantitativas de Recorrência RQA , sendo elas a Razão de Recorrência RR , o determinismo DET , o Comprimento Médio da Diagonal L e a Entropia $ENTR$.

Os parâmetros de defasagem temporal τ e de dimensão de imersão m utilizados para cada uma das RQA dos RP são os mesmos apresentados na Seção 3.3. Quanto ao raio da vizinhança ε (ou seja, o limiar de sondagem) utilizou-se o valor de 10% da média da série temporal, que corresponde aproximadamente ao desvio padrão da série de dados (MINDLIN & GILMORE, 1992; KOEBBE & MAYER-KRESS, 1992; ZBILUT & WEBBER, 1992; ZBILUT et al., 2002).

Devido ao número elevado de dados das séries temporais analisadas e as suas respectivas limitações computacionais, optou-se em fazer a RQA dos RP através de sucessivas janelas móveis (Windows shift) com passos fixos até cobrir toda a série temporal. As séries temporais teóricas tiveram uma janela móvel medindo 10% do tamanho da série e um passo medindo 1% do tamanho da série. Já as séries temporais micrometeorológicas, que possuem 140 mil dados, foram analisadas com uma janela móvel medindo 3 mil, dados que correspondem a aproximadamente um mês, e com um passo de 96 dados que corresponde a um dia, perfazendo assim 1430 análises para cada uma das seis medidas de RQA utilizadas neste trabalho. A utilização de janelas móveis possibilitou detectar as variações sensíveis da dinâmica do sistema micrometeorológico durante o período dos quatro anos de dados medidos.

A priori, nas figuras das três séries temporais micrometeorológicas (com os dados padronizados) observa-se um padrão sazonal bem comportando, o que também pode ser observado na figura da variância. Importante notar que mesmo a variância ter se apresentado flutuando ao redor do valor 1 durante os 4 anos das séries, os anos não foram iguais.

A densidade de pontos de recorrência medida RR_{Rn} apresentou valores menores do que 1% oscilando entre 1×10^{-3} e 2×10^{-3} no período chuvoso para 5×10^{-3} e 8×10^{-3} no período seco. Não houve pico na RR_{Rn} na seca de 2009. A RR_T oscilou sazonalmente com maior densidade de recorrência nos períodos chuvosos, em torno de 3×10^{-4} e um grande pico isolado na transição chuva-seca de 2009 atingindo 5×10^{-4} , e vales menores do que $0,1 \times 10^{-4}$ na seca com um pico isolado (2×10^{-4}) na seca de 2010. Quanto à RR_{Rh} , os valores encontrados, embora com flutuações, denotam uma maior recorrência no período chuvoso (1×10^{-4} até 2×10^{-4}) do que no período seco ($0,5 \times 10^{-4}$). Destina-se atenção especial para um pico isolado medindo $0,5 \times 10^{-4}$ na transição chuva-seca de 2009. O comportamento identificado na transição chuva-

seca 2009 com ausência de pico RR_{Rn} e presença de pico RR_T e RR_{Rh} pode estar relacionado com fim do alagamento do Pantanal. Neste período o solo Pantaneiro ainda se mantém encharcado resultando em altos valores de evaporação do solo o que estabiliza a umidade e também a temperatura.

A previsibilidade do sistema é dada pela DET que varia de 0 (zero por cento) para nenhuma previsão até 1 (cem por cento) para ótima previsão. A medida DET_{Rn} oscilou sazonalmente com picos bem definidos de 80% no período seco e 10% no vale do período chuvoso, que por sua vez é acompanhado de um pequeno pico isolado no meio desse mesmo período com amplitude em torno de 40%. A DET_T apresentou flutuação em torno de 60% em toda a análise, acompanhada de vales no período seco em torno de 20%. Nota-se a ausência desses vales no período seco de 2009. Quanto à DET_{Rh} , esta apresentou flutuações em torno de 40% em toda a análise com alguns vales medindo 10% e picos medindo 70% localizados nas transições entre as sazonalidades.

A medida do Comprimento Médio da Diagonal L (também chamada medida de complexidade) representa o tempo médio em que dois segmentos da trajetória do atrator “caminham” próximas uma da outra. Estabeleceu-se como comprimento mínimo l como sendo de 2 estados no RP , logo os dados de L plotados se referem a comprimentos l de dois estados. Assim o L_{Rh} apresentou comportamento sazonal com picos maiores no período seco medindo 8 estados do atrator, e vales o período chuvoso medindo 4 estados acompanhados de pequenos picos menores nesses vales medindo cerca de 6 estados. O L_T apresentou flutuações em torno de 6 estados com alguns picos na seca chegando a 10 estados. Já a L_{Rh} apresentou flutuações em torno de 5 estados com um pico de 12 estados na seca de 2009.

A frequência de distribuição das linhas diagonais, medida $ENTR$, é dada como a soma de todos os comprimentos recorrentes escalonados na escala logarítmica. A sua interpretação é que quanto maior for o valor da entropia, mais organizado está o sistema, maior a sua complexidade e os estados tende a ser mais parecidos ou iguais. Por outro, lado quanto menor os valores da entropia, o sistema estará menos complexo, seus dados mais aleatórios e os estados (os dados) mais diferentes. Assim, a $ENTR_{Rn}$ apresentou maiores distribuições de frequências nos períodos secos com picos próximos ao valor 2, decaindo no período chuvoso com

valores cada vez menores chegando à zero na chuva 2008-2009 e 2009-2010. A $ENTR_T$ apresentou flutuações em torno do valor 1 e 1,5 durante toda a análise. Obteve no período seco três picos próximos ao valor 2 e dois valores zero (0). Também registraram-se três vales com valores 0,5 no período chuvoso. Isso demonstra que a complexidade do sistema não necessariamente é dependente da sazonalidade. A medida $ENTR_{Rh}$ comportou-se com flutuações entre os valores 0,5 e 1 em toda a análise, com cinco vales chegando até zero e sendo três deles próximos ao fim do período seco.

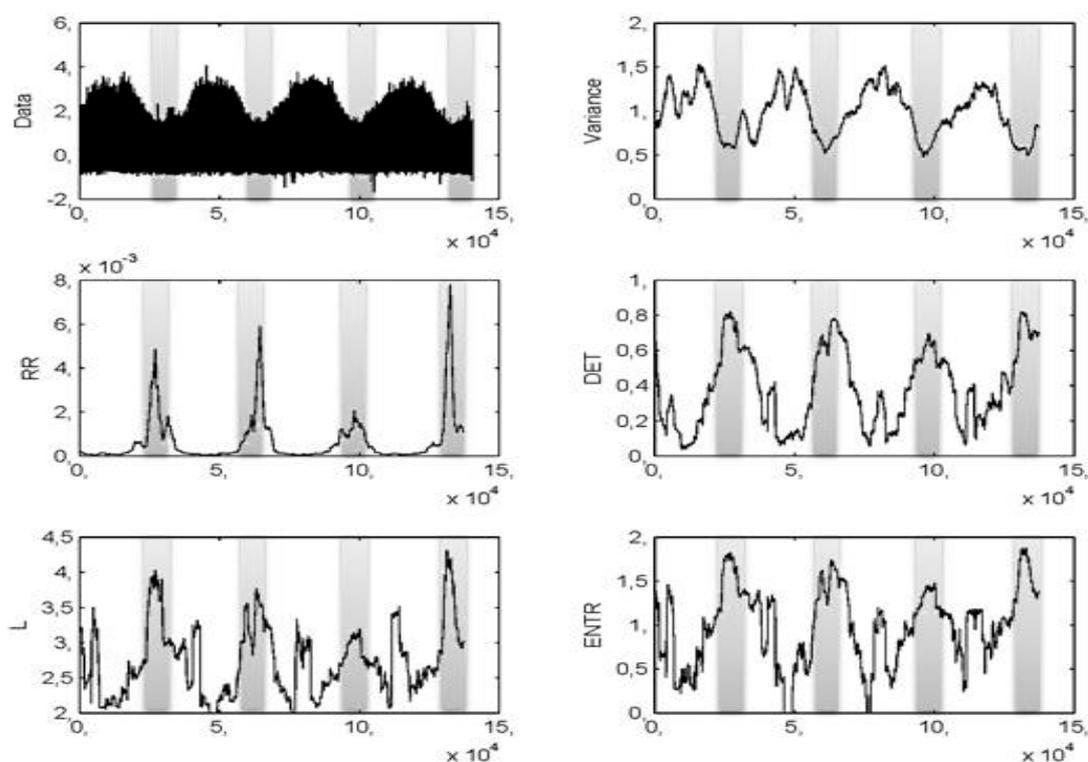


Figura 28. Análise de Quantificação de Recorrência RQA da variável microclimática Rn .

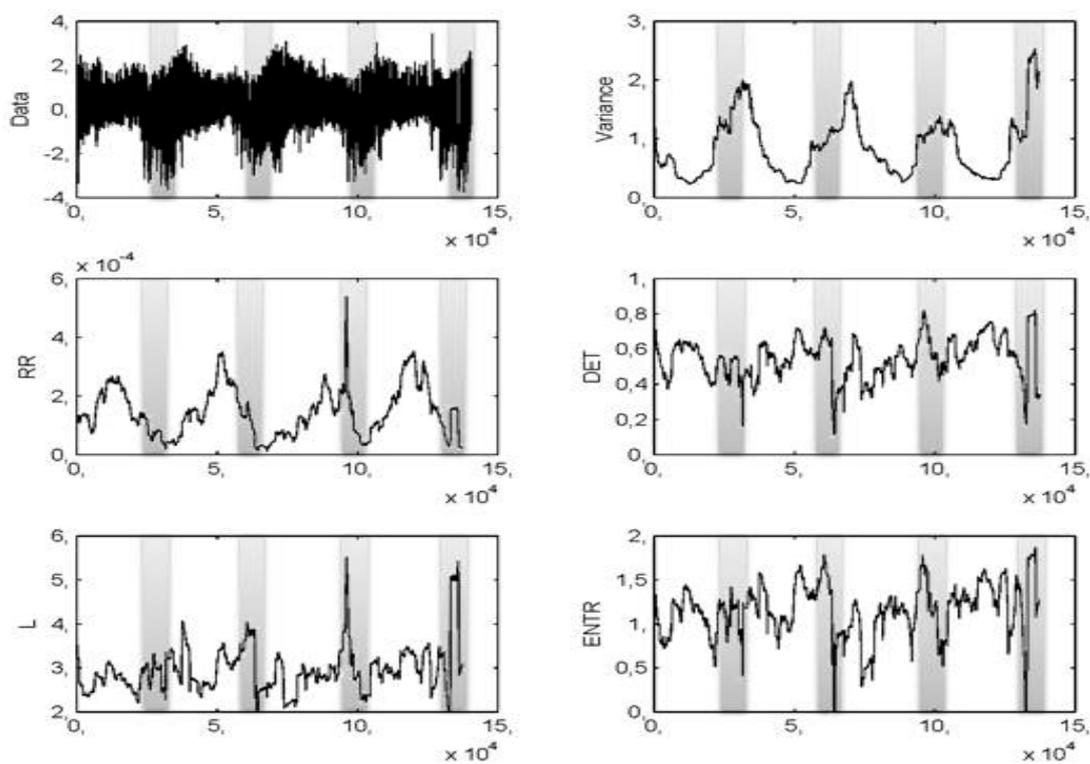


Figura 29. Análise de Quantificação de Recorrência **RQA** da variável microclimática **T**

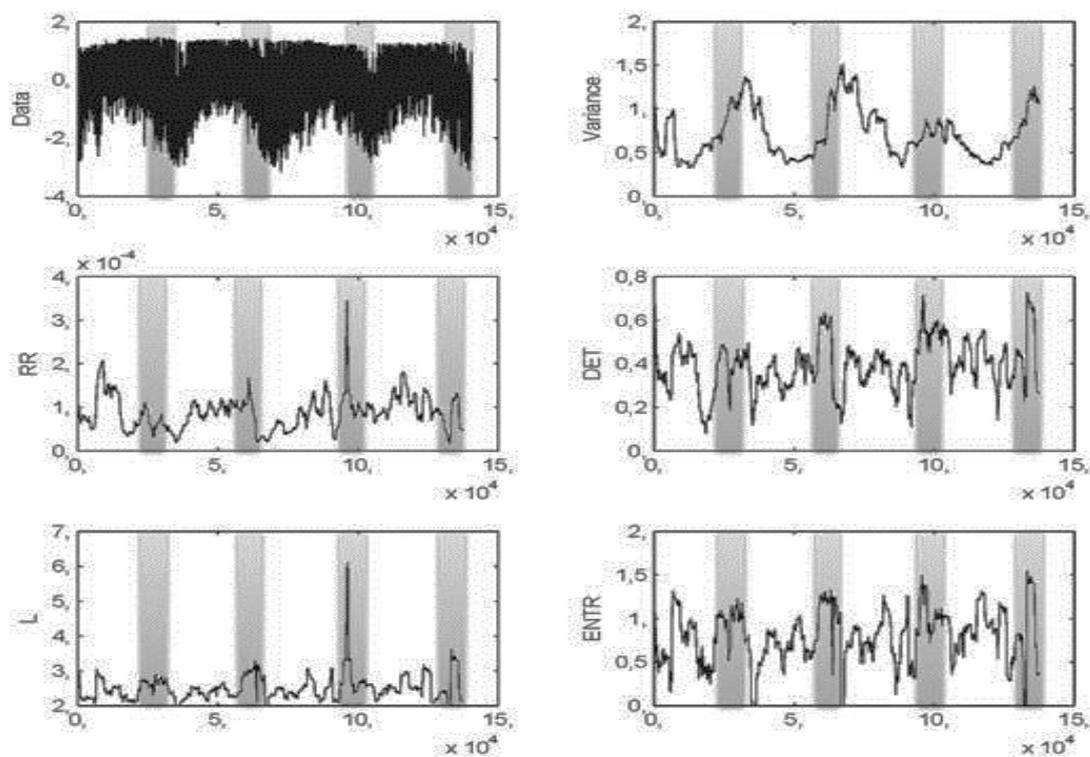


Figura 30. Análise de Quantificação de Recorrência **RQA** da variável microclimática **Rh**.

4.4.3. Expoentes de Lyapunov λ

O expoente de Lyapunov λ é um valor que serve para caracterizar a dinâmica do atrator. Este parâmetro é a medida da taxa da divergência das trajetórias vizinhas do atrator, quantificando a dependência (ou sensibilidade) às condições iniciais. Como este trabalho visa modelar um sistema micrometeorológico, este parâmetro provê o quanto se perde de informação enquanto desloca-se ao longo do atrator. Desta maneira, a existência de um λ positivo implica em órbitas de pouco previsíveis a imprevisíveis, caracterizadas por flutuações irregulares.

Apresentam-se nesta Seção as aproximações numéricas do λ associado às séries temporais teóricas e às séries micrometeorológicas usando o algoritmo de Kantz (1994). Na Figura 31 estão plotados as evoluções temporais dos cálculos do maior expoente de Lyapunov para as séries inteiras que serão chamadas λ_{global} . Os resultados do Maior Expoente de Lyapunov dos atratores associados às séries micrometeorológicas foram $\lambda_{global(Rn)} = 0,0091$, $\lambda_{global(T)} = 0,0061$ e $\lambda_{global(Rh)} = 0,0073$. Observa-se que, as séries microclimáticas apresentaram valores positivos para λ_{global} o que sugere presença de caos em suas dinâmicas (Figura 31).

Em prosseguimento, optou-se também em calcular um λ_{local} para os dados de forma mensal e verificar as variações, visto os resultados da RQA da Seção anterior apresentarem fortes quantificações das variações sazonais. A Figura 32 retrata os valores encontrados para os cálculos feitos mês a mês dos quatro anos das séries micrometeorológicas. Utilizando apenas um mês, ou seja, um recorte da dinâmica total analisada anteriormente, os resultados obtidos apresentaram em média valores menores, com $\lambda_{local(Rn)} = 0,0030$, $\lambda_{local(T)} = 0,0020$ e $\lambda_{local(Rh)} = 0,0025$.

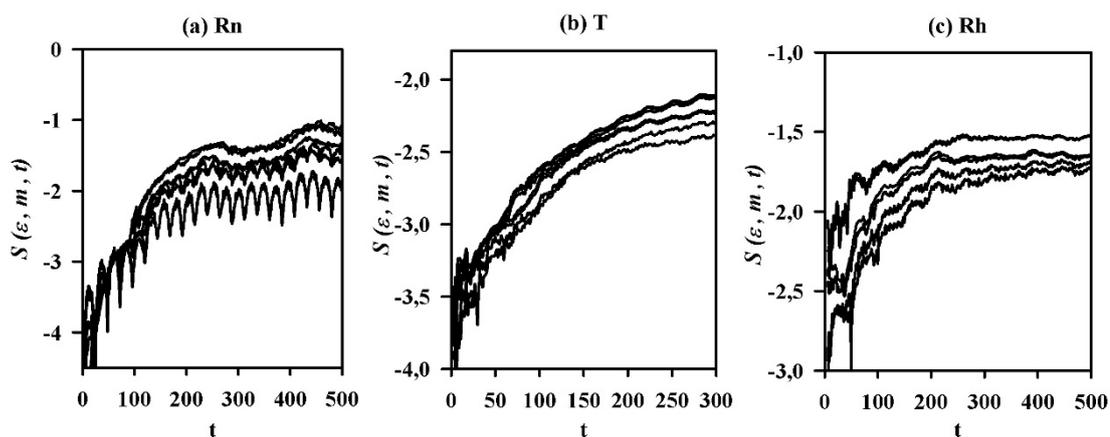


Figura 31. Maior Expoente de Lyapunov λ das variáveis microclimáticas global (série temporal completa).

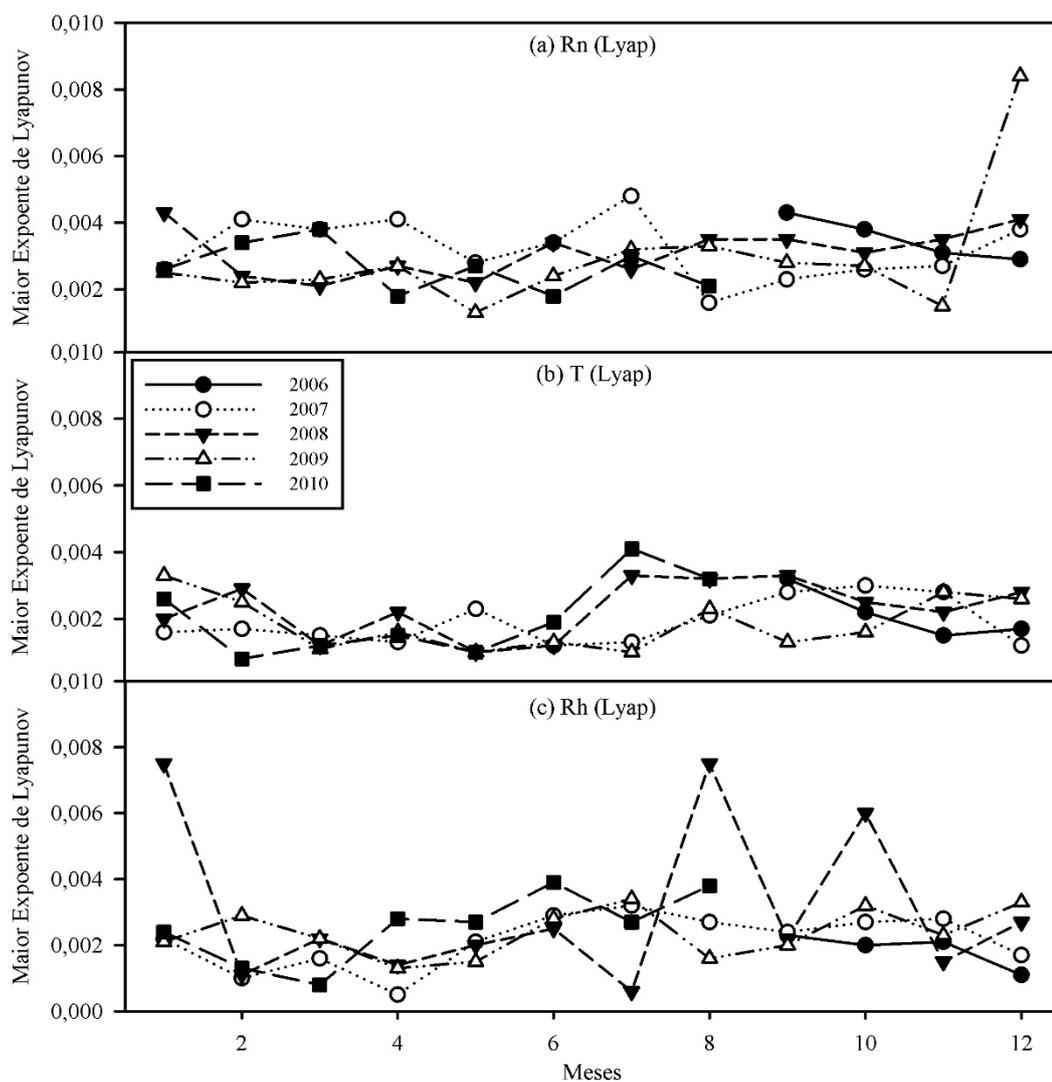


Figura 32. Maior Expoente de Lyapunov λ das variáveis microclimáticas local (séries mensais).

4.4.4. Dimensão de Correlação D_2

Em oposição à técnica do Exponente de Lyapunov λ que mede a dinâmica do atrator associado à série temporal estudada, a Dimensão de Correlação D_2 se baseia na quantificação da geometria do atrator. Por definição D_2 , aproximação da dimensão fractal, é uma técnica estática que fornece a medida da dispersão (ou densidade) de pontos do atrator no espaço de estados. Também provê uma distinção entre dados aleatórios e dinâmica não linear.

Da mesma forma que na Seção anterior, são apresentados aqui os resultados calculados para todas as séries inteiras (global), e em seguida os resultados mês a mês durante os quatro anos (local) para as séries micrometeorológicas.

Reconstruídos os atratores de acordo com os parâmetros apresentados na Seção 3.3 e variando a dimensão de imersão m de 1 até 10 obteve-se os seguintes resultados para as séries micrometeorológicas quais sejam: a $D_{2(Rn_{global})} = 4,14 \pm 0,05$ com $m = 6$, $D_{2(T_{global})} = 3,93 \pm 0,03$ com $m = 6$ e a $D_{2(Rh_{global})} = 4,15 \pm 0,02$ com $m = 6$ (Figura 33).

Os resultados quanto às análises mensais das séries micrometeorológicas foram, em média, $D_{2(Rn_{local})} = 3,44 \pm 0,51$, $D_{2(T_{local})} = 2,80 \pm 0,26$ e $D_{2(Rh_{local})} = 2,93 \pm 0,20$ com $m = 6$ para todas as análises (Figura 34).

O número inteiro mais próximo acima do valor do parâmetro D_2 denota uma importante aplicação da matemática fractal que é determinar o menor número de equações diferenciais de primeira ordem que podem conter as características qualitativas do sistema dinâmico estudado (GRASSBERGER & PROCACCIA, 1983). Os valores encontrados satisfazem tanto a relação de Takens (1981) o qual afirma que para se obter um resultado confiável deve-se calcular a D_2 até m , com $m \geq 2D_2 + 1$. E também satisfazem a relação de Eckmann & Ruelle (1992) na qual $D_{2(max)} = 2 \log_{10} N$, onde N é o número de dados da série temporal.

Por ser a mais comumente medida de estações meteorológica e uma das mais relacionadas com as outras variáveis do ambiente, a variável temperatura possui diversos estudos na literatura quanto à Dimensão de Correlação D_2 (Tabela 4), e os resultados encontrados, embora de provenientes de diferentes fontes de dados e com diferentes amostragens temporais, corroboram os dados estimados neste trabalho.

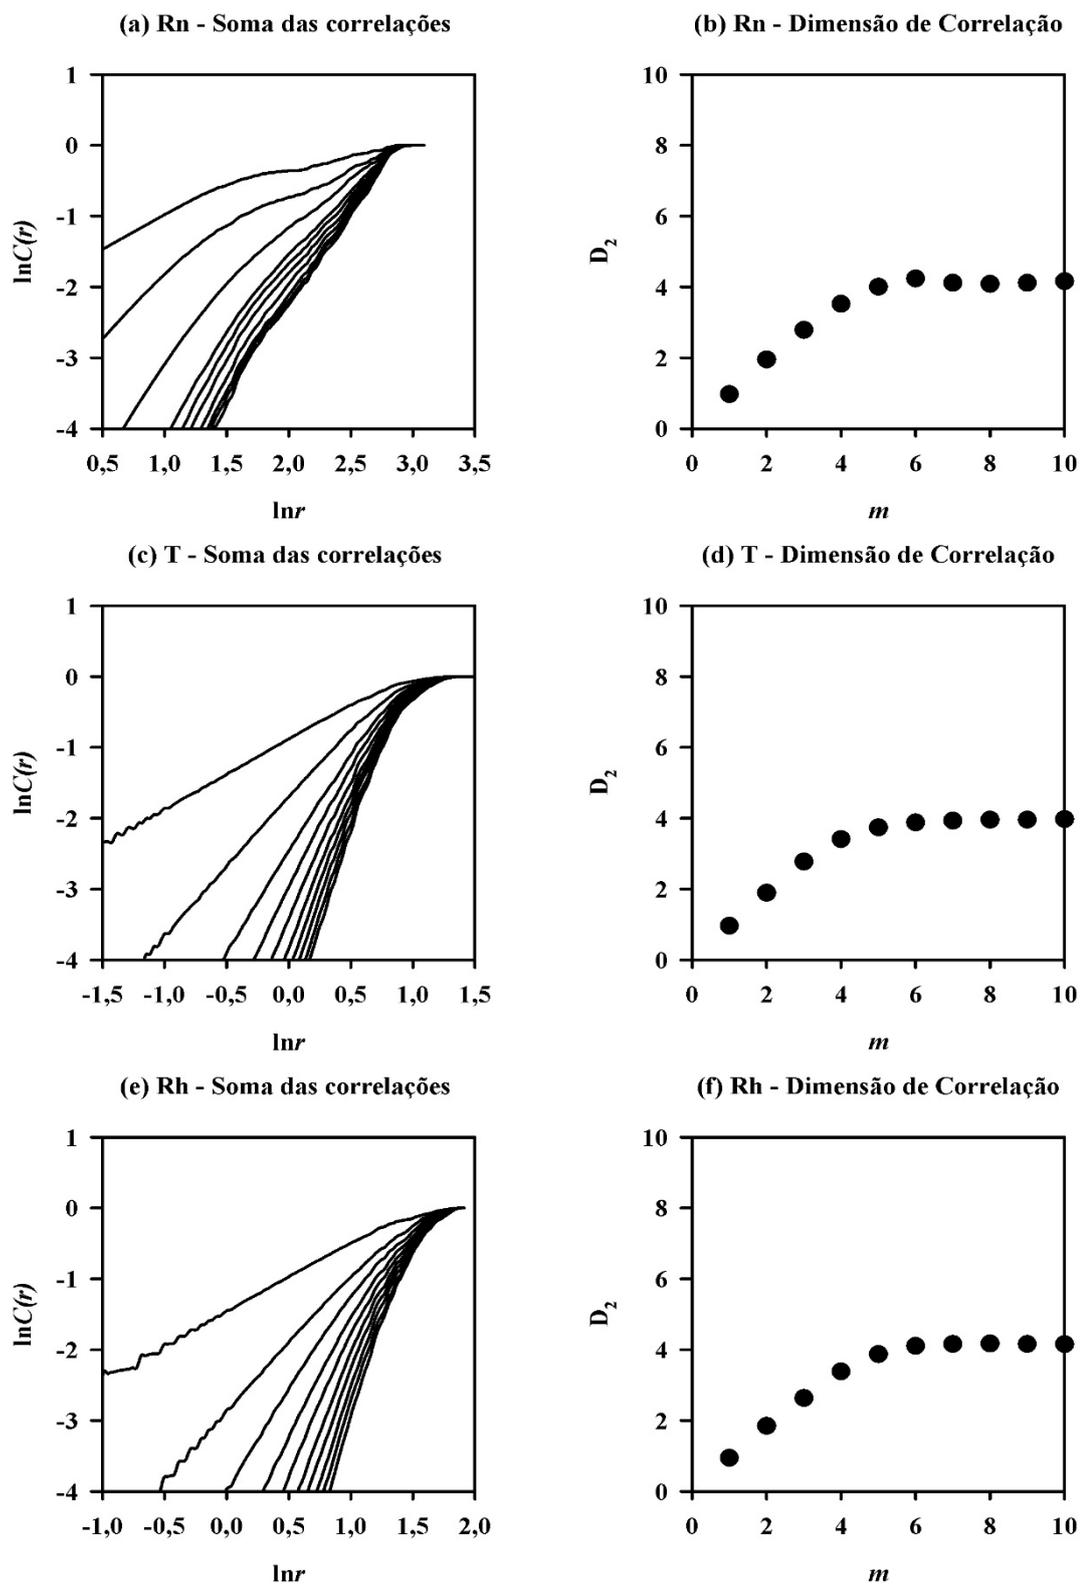


Figura 33. A esquerda $\ln C(r)$ vs $\ln r$ para valores crescentes de m , e a direita saturação da dimensão de correlação D_2 versus dimensão de imersão m para o atrator reconstruído a partir das variáveis micrometeorológicas.

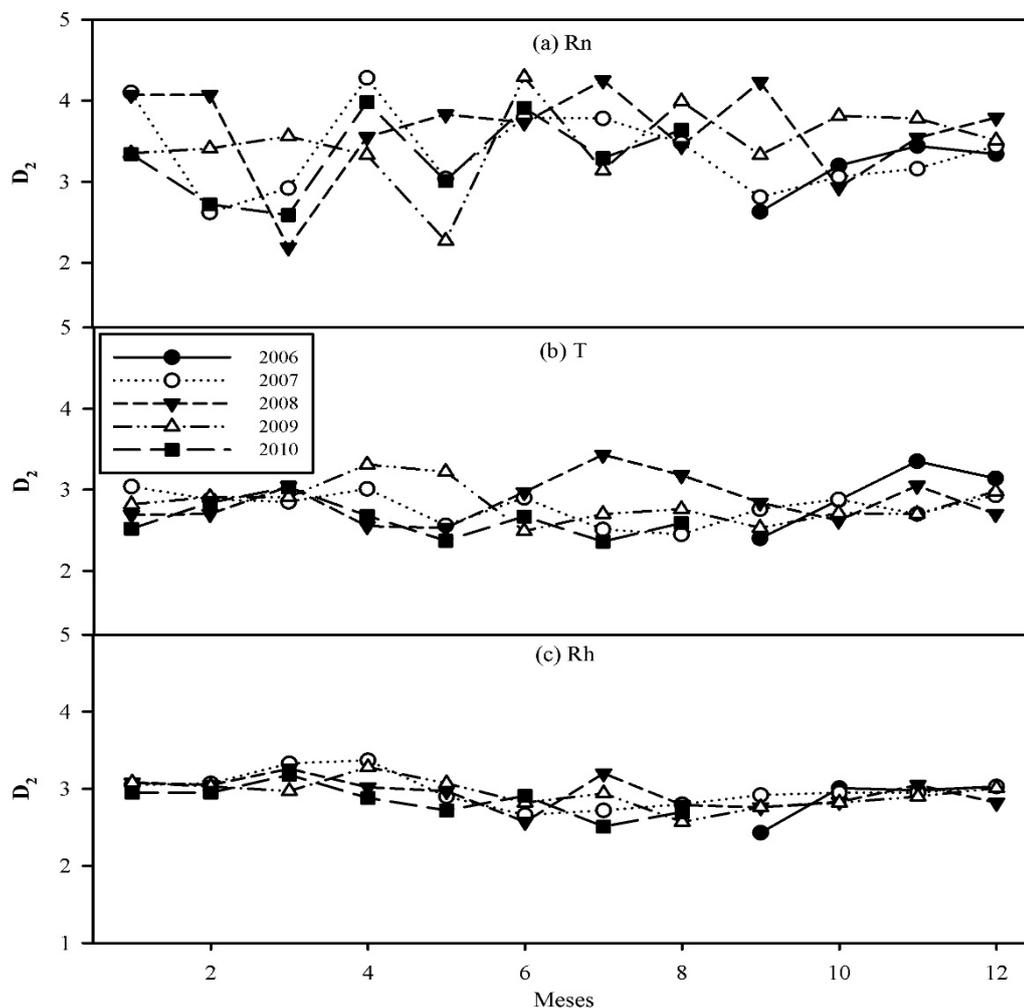


Figura 34. Dimensão de Correlação D_2 (local) das variáveis microclimáticas (séries mensais).

Tabela 4. Valores de D_c de Temperatura na literatura

Referências	D_c
Este trabalho	3,05
Campanharo et al., 2008	3,50
Jaramillo & Puente, 1993	4,50
Xin et al., 2001	3,26
Zeng & Pielke, 1993	3,50
Jayawardena & Gurung, 2000	3,85
Berndtsson et al., 1994	<4

4.5. PREDIÇÃO NÃO LINEAR E VERIFICAÇÃO DO MODELO

O método da Predição Não Linear Simples usado neste trabalho possibilita fazer previsões sem que se conheçam as equações de governo do fenômeno físico associado ao sistema (SAVI, 2006). Este método é baseado na reconstrução do atrator associado a uma série temporal medida, partindo de uma série temporal escalar (passado) com objetivo de determinar uma estimativa para os seus valores seguintes (futuro) fornecendo informações precisas sobre a dinâmica do sistema (KANTZ & SCHREIBER, 2004). Assim são feitas previsões sem a construção explícita de um modelo para uma série temporal específica.

A seguir são apresentados os resultados estimados dos parâmetros que envolvem a predição, tais como o tempo máximo de previsão confiável ξ baseado no inverso do expoente de Lyapunov λ , a Predição Não Linear Simples comparada com as séries temporais medidas juntamente com as medidas de erros da predição.

4.5.1. Tempo Máximo de Previsão Confiável

Apresenta-se na tabela abaixo (Tabela 5) o tempo máximo de previsão confiável ξ (também chamado “tempo de Lyapunov”), baseado na ideia de que se o atrator possui pelo menos um $\lambda_{max} > 0$, então o crescimento das perturbações é controlado por λ_{max} que conduz a uma divergência exponencial das trajetórias. Assim, a maneira quantitativa de estimar a previsibilidade do sistema, chamado tempo máximo de previsão confiável ξ , é definido como o intervalo da amostra experimental τ dividido pelo maior expoente de Lyapunov λ_{max} (TSONIS, 2001; GOMES & VARRIALE, 2004; CHAUDHURI, 2006; MILLÁN et al., 2009).

Tabela 5. Tempo Máximo de Previsão Confiável ξ (Tempo de Lyapunov).

Variáveis/Parâmetros	λ_{global}	ξ_{global}	λ_{local}	ξ_{local}
Rn	0,0091	109 dados ou 1,14 dias	0,0030	333 dados ou 3,47 dias
T	0,0061	163 dados ou 1,70 dias	0,0020	500 dados ou 5,21 dias
Rh	0,0073	136 dados ou 1,42 dias	0,0025	400 dados ou 4,16 dias

Os resultados apresentados na Tabela 5 são apresentados em termos do parâmetro Maior Expoente de Lyapunov que calculado para a série total, ou seja, de 1º de setembro 2006 até 1º de setembro de 2010, e que foi chamado de λ_{global} , que por sua vez gerou o parâmetro ξ_{global} . Da mesma forma, para o parâmetro Maior Expoente de Lyapunov calculado para recortes mensais dessa mesma série temporal, chamado λ_{local} que gerou ξ_{local} . Isto se justifica pela forte sazonalidade encontrada na análise não-linear *RP* e sua quantificação *RQA*, indicando a necessidade da estimativa desses parâmetros em termos globais e locais, ou seja, não é possível prever séries temporais de períodos chuvosos usando dados de seca, e vice versa.

Na próxima Seção foram apresentadas as previsões das séries temporais utilizando o limite de previsão ξ em termos globais e locais, e suas respectivas medidas de erros de previsão.

4.5.2. Predição Não Linear Simples e Medidas de Erro de Predição

Nesta Seção foram apresentados os resultados da predição não-linear simples das séries temporais de *Rn*, *T* e *Rh* a partir de medidas em torre micrometeorológica no Pantanal de Mato Grosso. A predição é feita mês a mês para os doze meses do ano de 2007 levando em conta o parâmetro tempo de previsão confiável ξ global e local. Esta postura parte da avaliação do número de pontos utilizados na predição, que depois de alguns testes, resultou em previsões melhores quando utilizado apenas o mês imediatamente anterior aos dados a serem preditos. As séries temporais medidas não foram submetidas a nenhum tipo de filtragem no intuito de trabalhar com a natureza intrínseca do sistema micrometeorológico ao qual a dinâmica da série é associada, e de evitar perder qualquer informação em processos de filtragem.

Assim sendo, utiliza-se uma série medida de um mês anterior (aproximadamente 3000 dados) para estimar uma série prevista referente ao mês seguinte, da qual são medidos os erros dentro do tempo estabelecido pelo parâmetro de previsão confiável ξ , especificados na Tabela 5.

Com o objetivo de estabelecer uma verificação do modelo, os resultados da predição são plotados juntamente com os respectivos trechos das séries medidas do futuro que são conhecidos. Em seguida foram calculadas as Medidas de Erro de

Predição comparando a série predita com a série medida. Desta forma, apresenta-se a seguir, mês a mês para os doze meses do ano de 2007, e para as três variáveis, iniciando na Figura 35 até a Figura 70 os resultados da predição e suas respectivas medidas de erro. Estes resultados, referentes à verificação do modelo utilizado, demonstram a sua capacidade de capturar o comportamento dinâmico das trajetórias dos atratores reconstruídos no espaço de fase, e conseqüentemente o comportamento geral das três séries temporais micrometeorológicas medidas Rn , T e Rh .

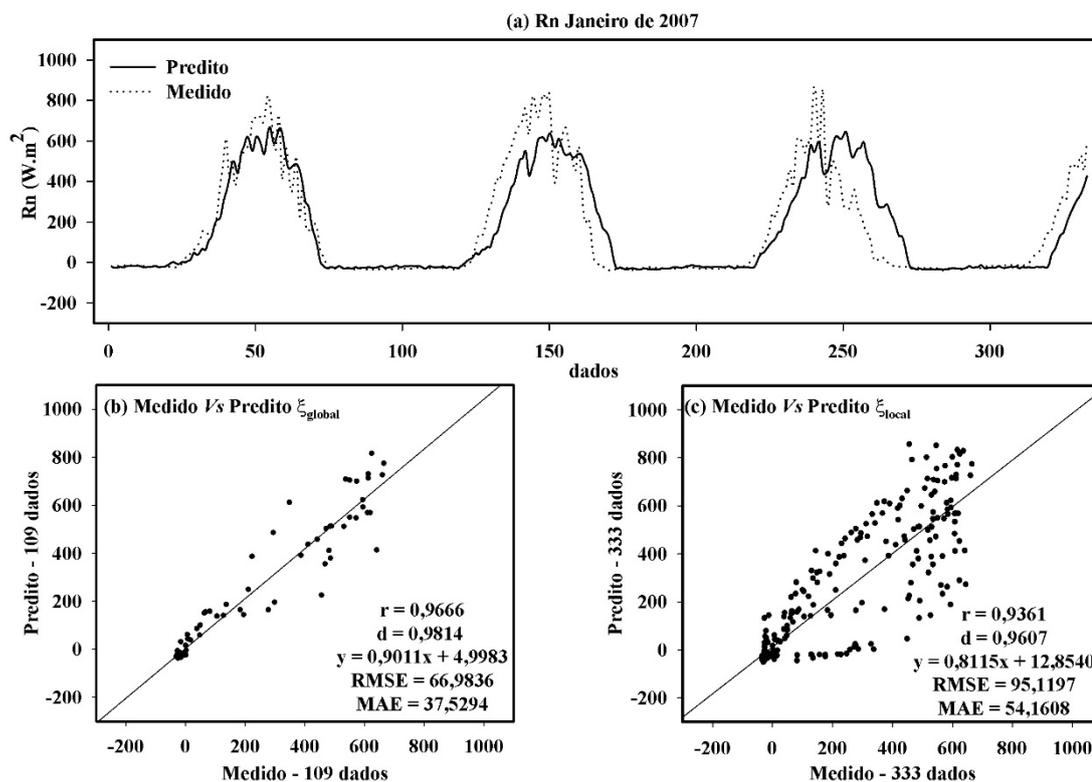


Figura 35. (a) Série temporal de R_n medida e predita, janeiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

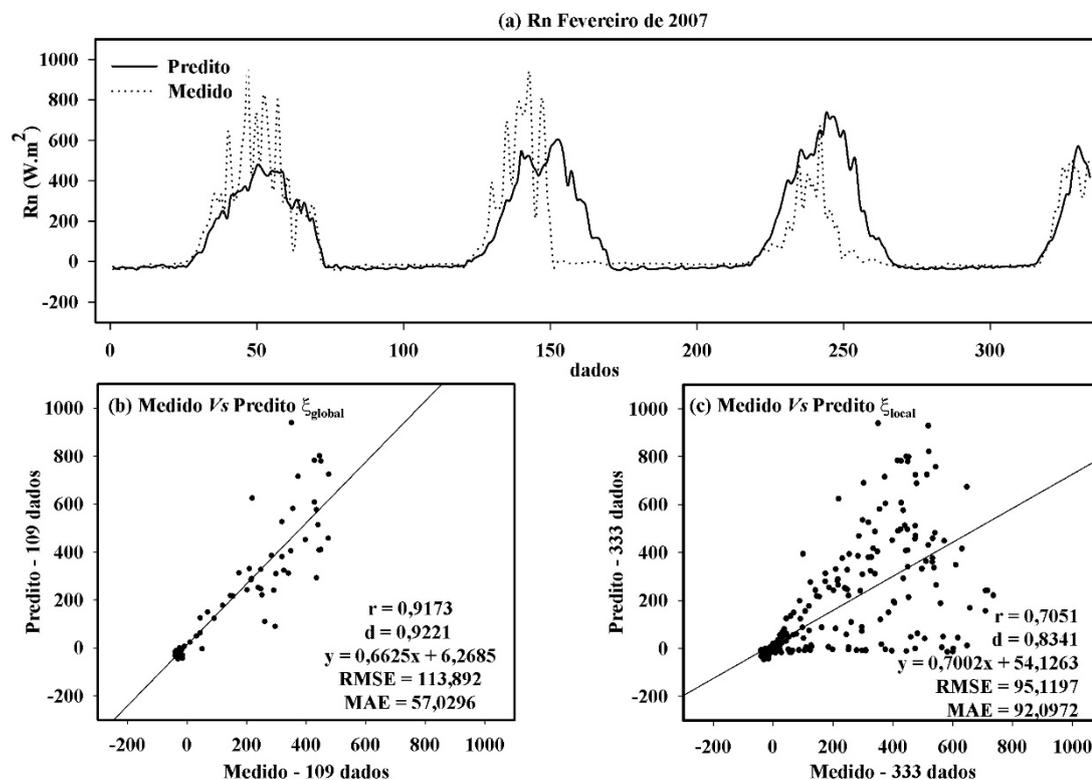


Figura 36. (a) Série temporal de R_n medida e predita, fevereiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

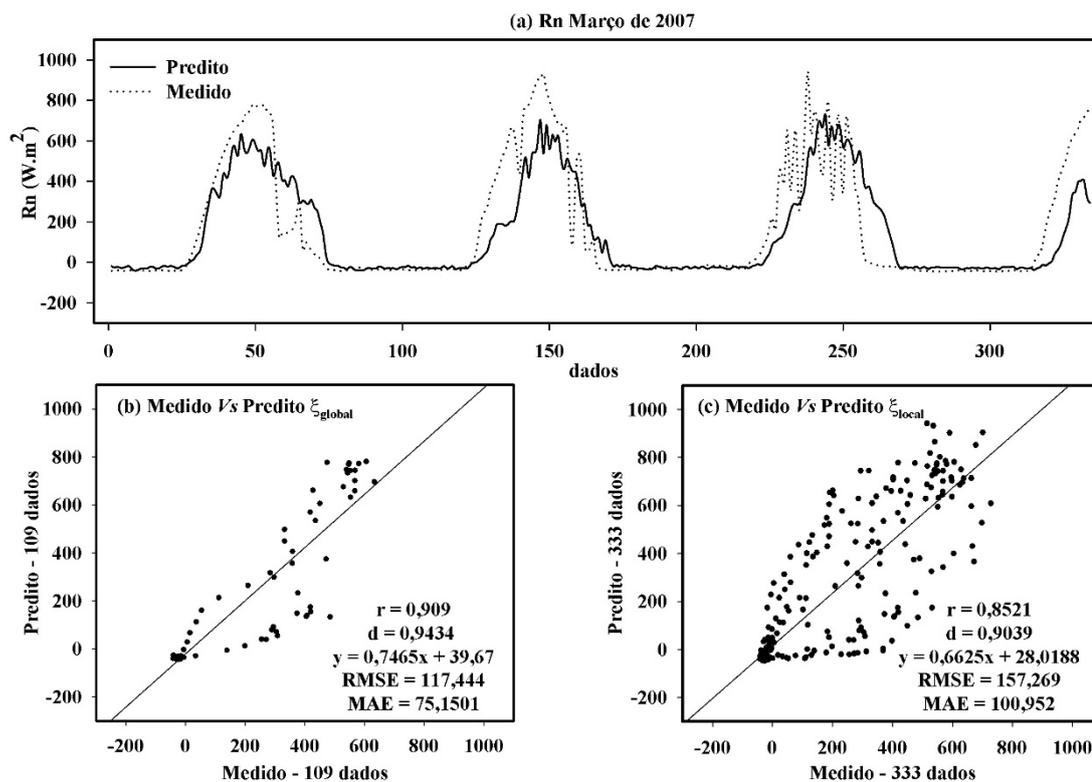


Figura 37. (a) Série temporal de R_n medida e predita, março de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

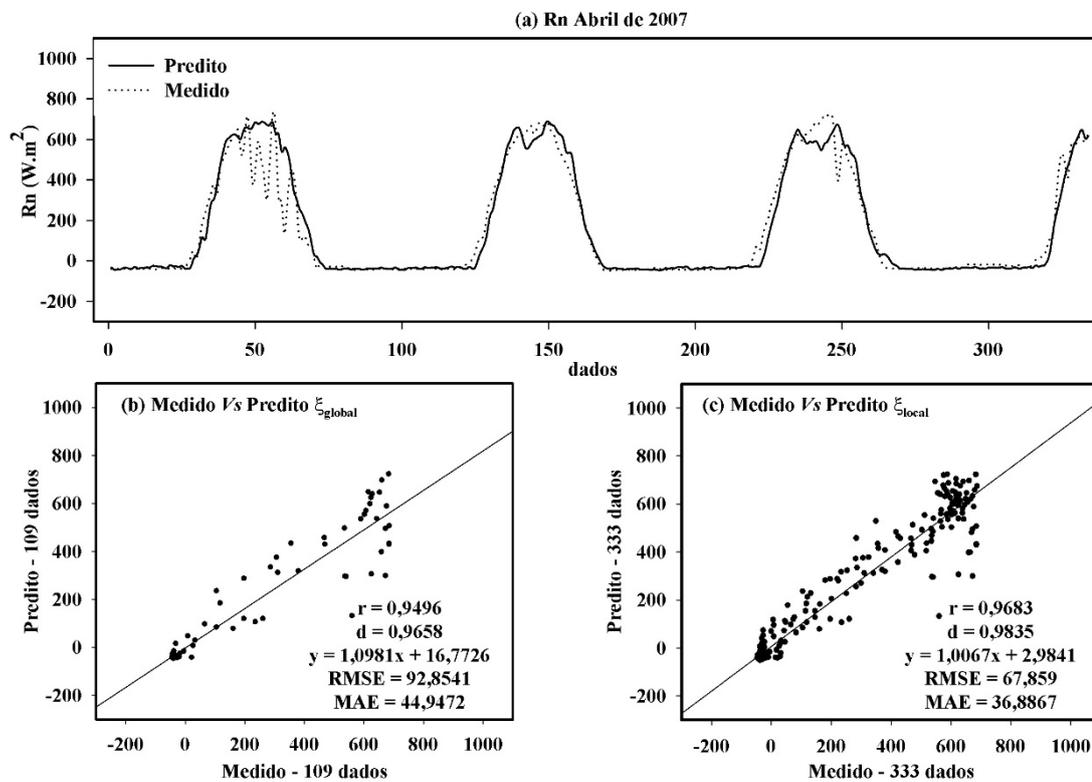


Figura 38. (a) Série temporal de R_n medida e predita, abril de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

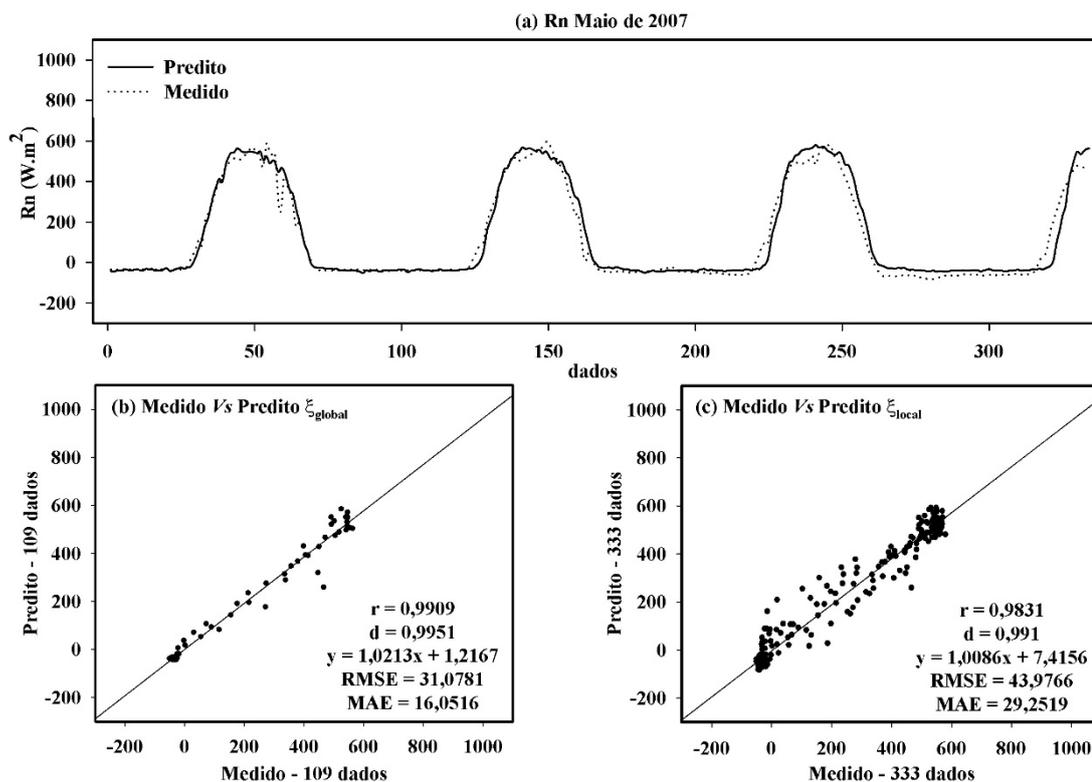


Figura 39. (a) Série temporal de Rn medida e predita, maio de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

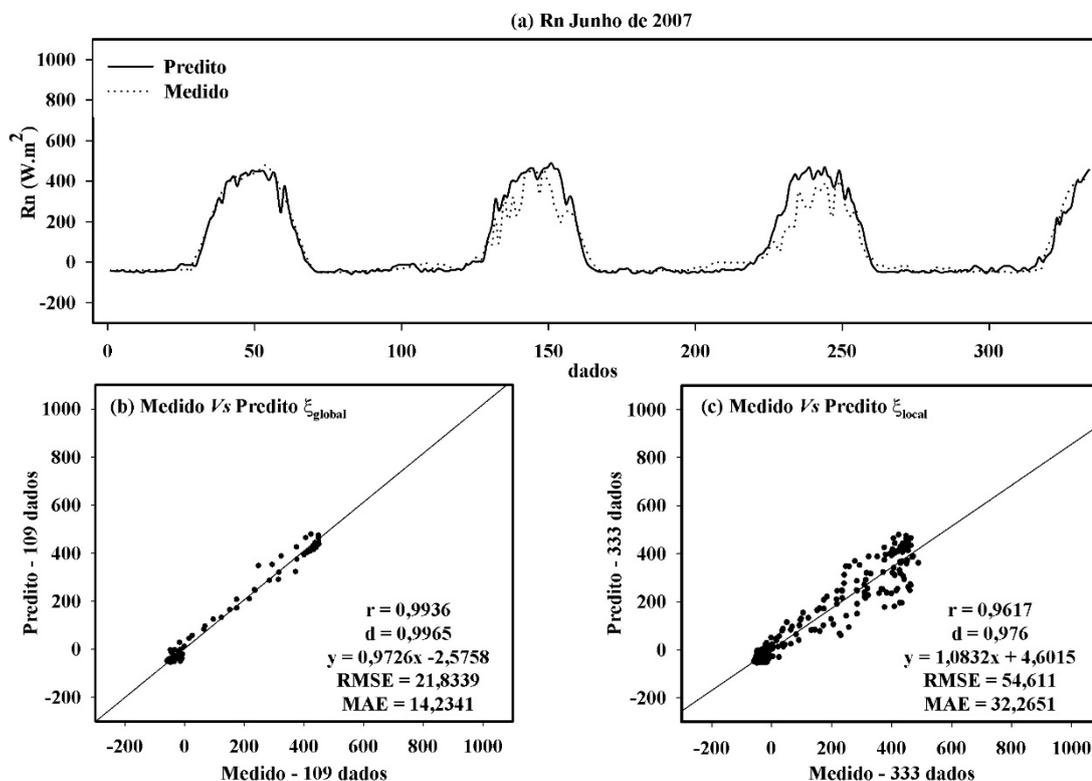


Figura 40. (a) Série temporal de Rn medida e predita, junho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

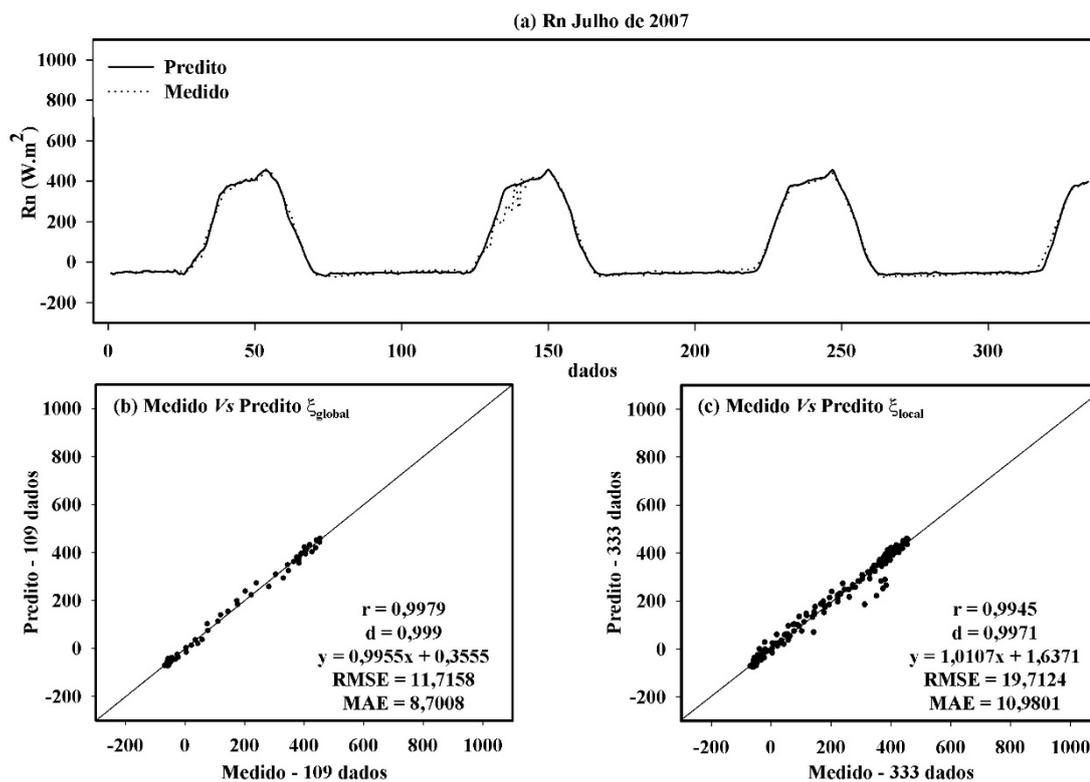


Figura 41. (a) Série temporal de Rn medida e predita, julho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

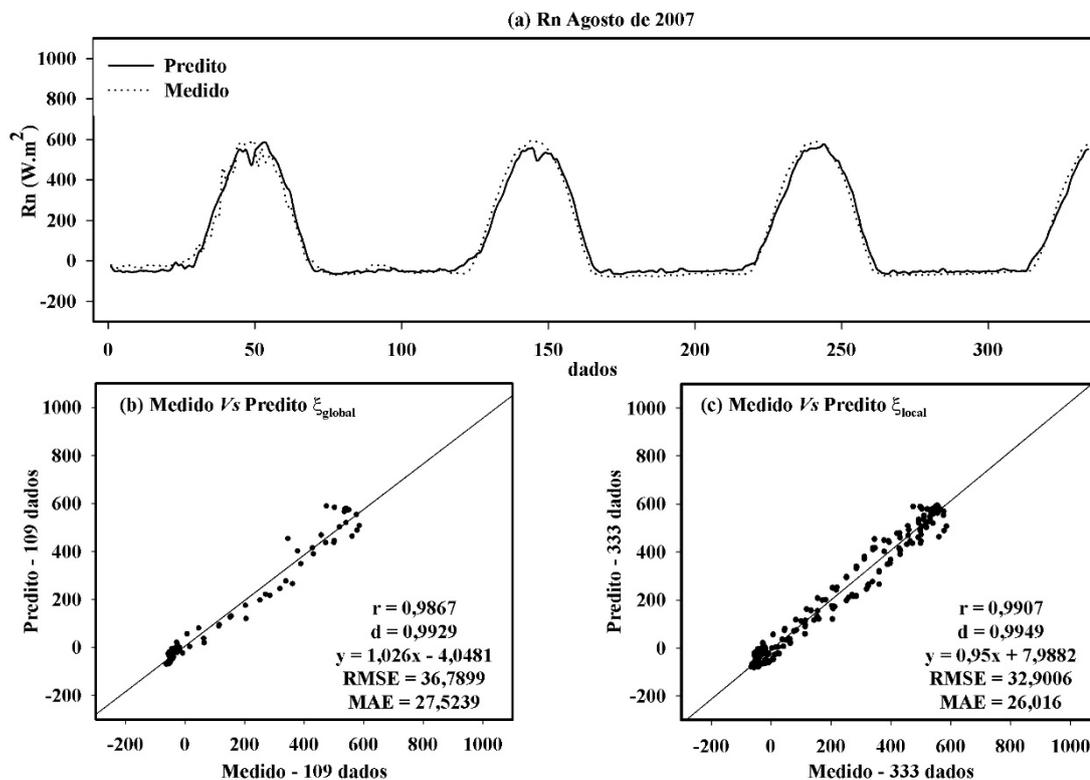


Figura 42. (a) Série temporal de Rn medida e predita, agosto de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

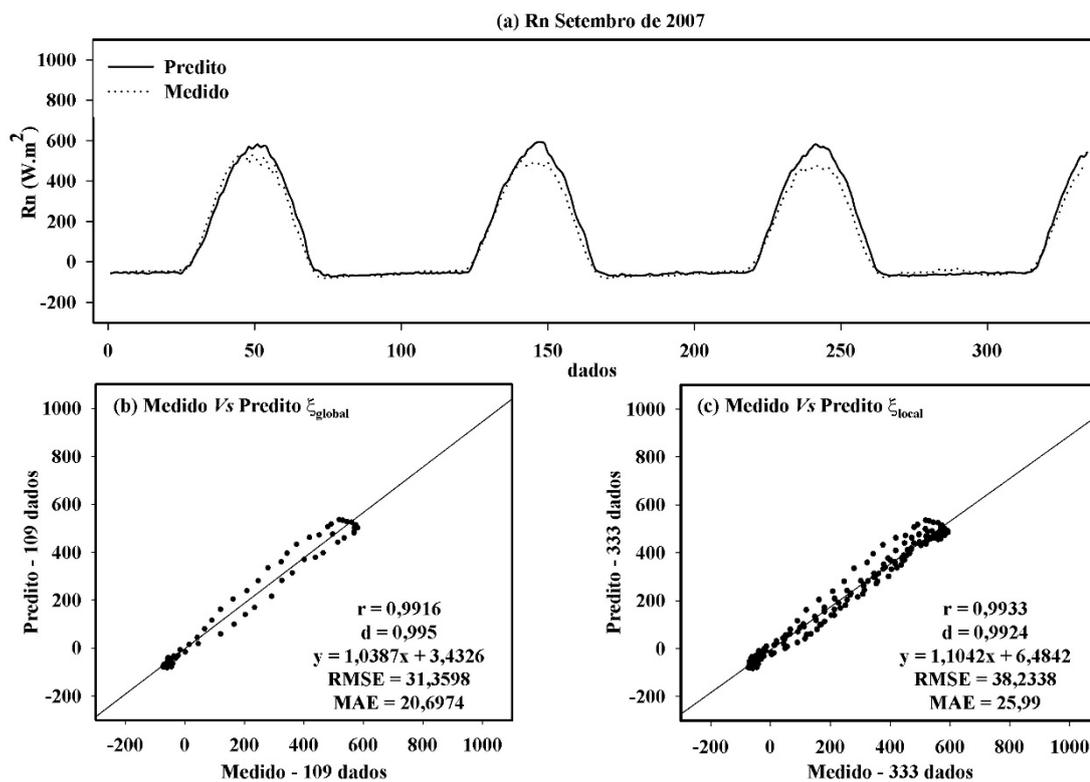


Figura 43. (a) Série temporal de R_n medida e predita, setembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

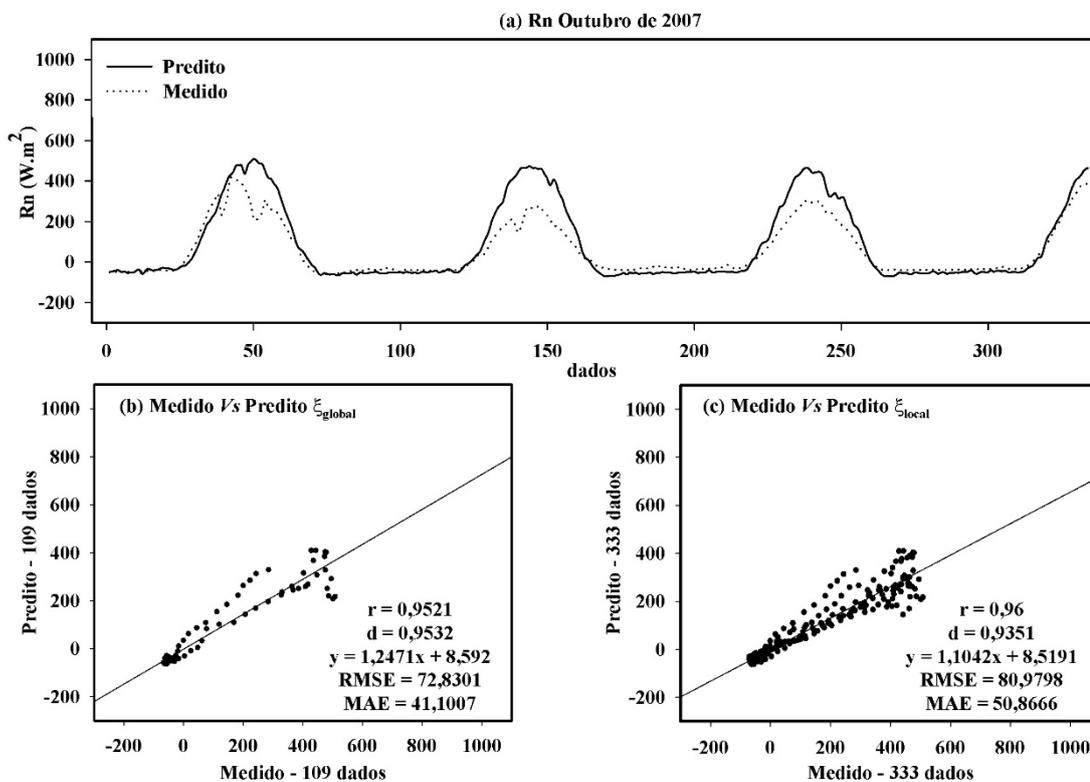


Figura 44. (a) Série temporal de R_n medida e predita, outubro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

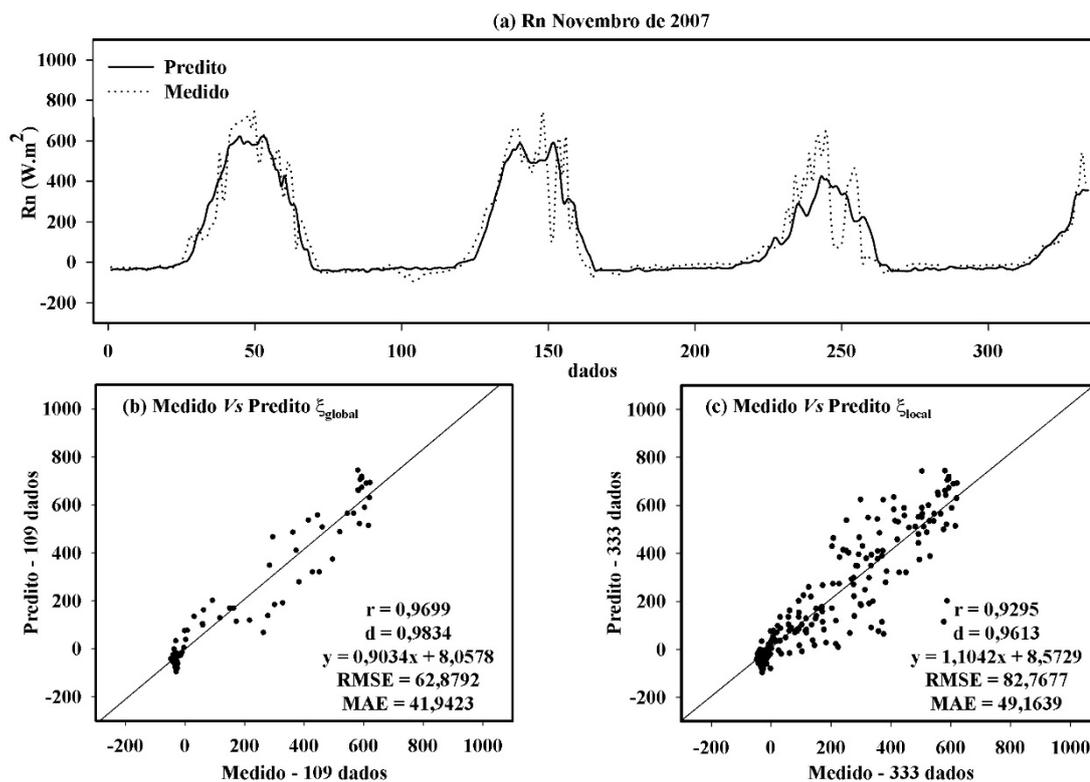


Figura 45. (a) Série temporal de R_n medida e predita, novembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

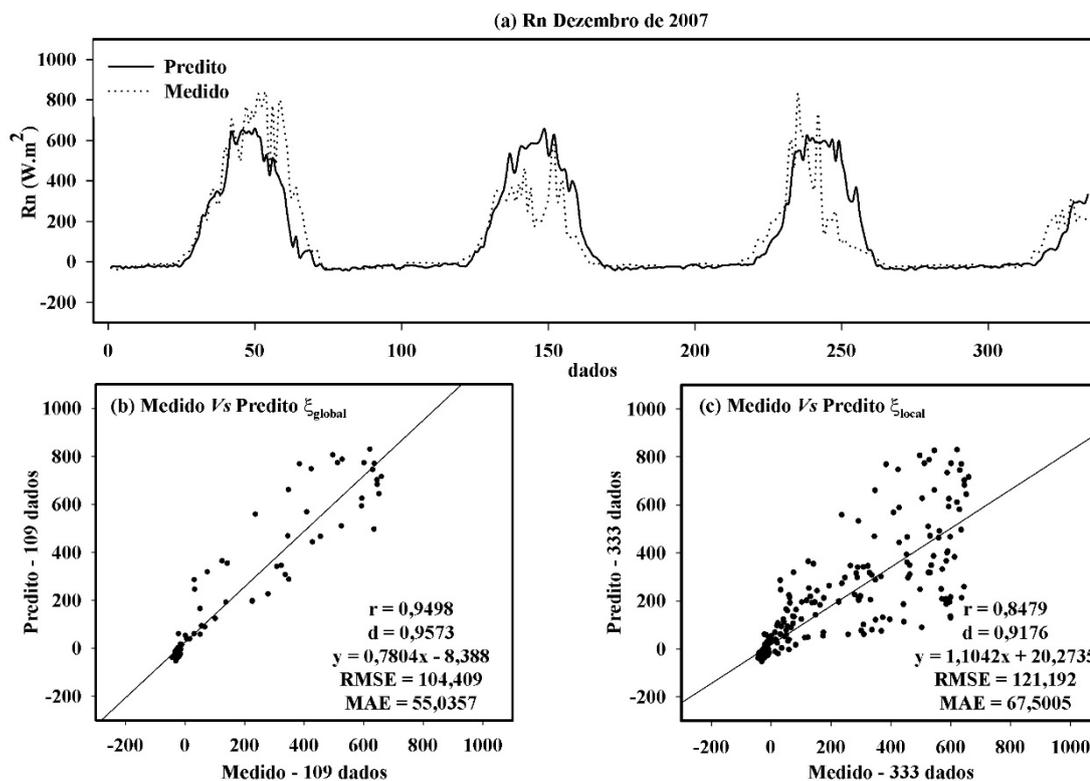


Figura 46. (a) Série temporal de R_n medida e predita, dezembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

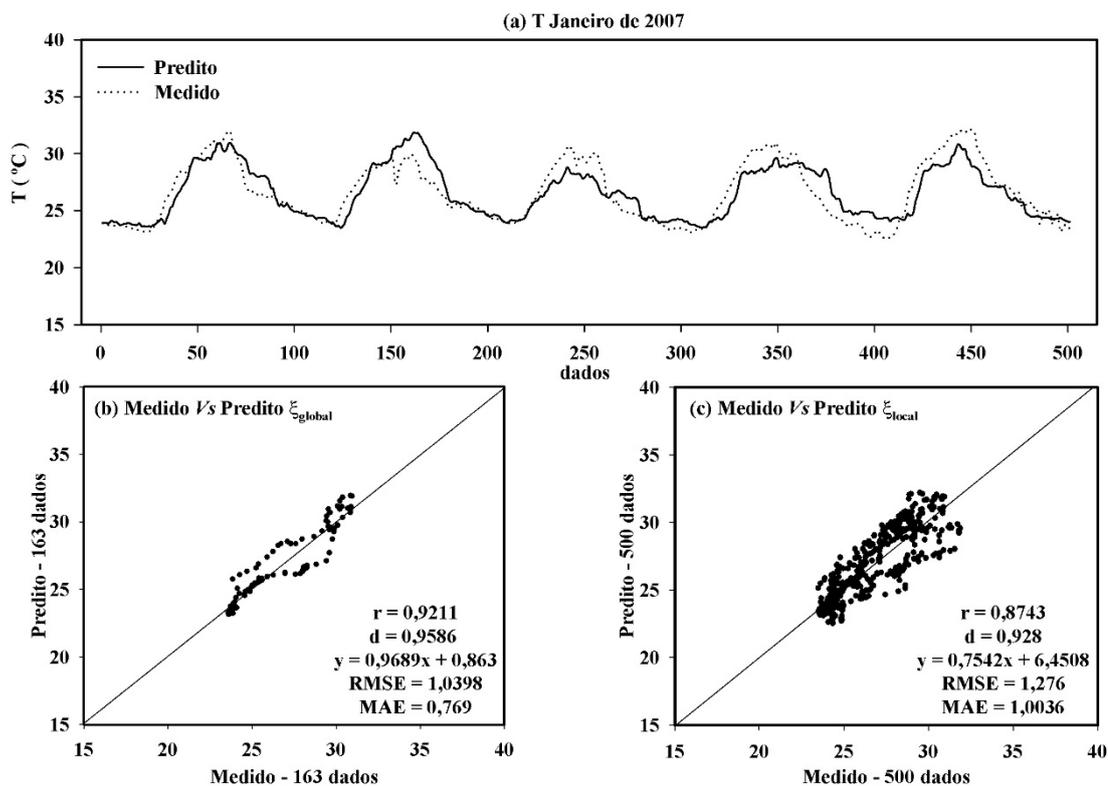


Figura 47. (a) Série temporal de T medida e predita, janeiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

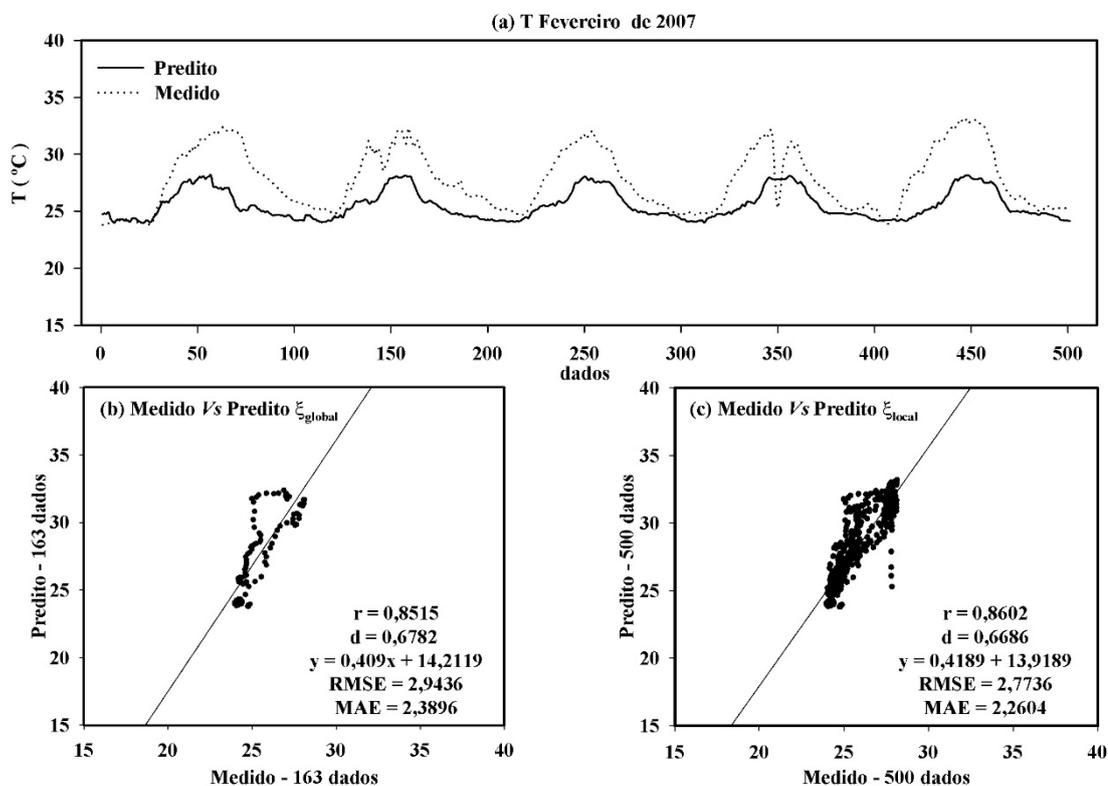


Figura 48. (a) Série temporal de T medida e predita, fevereiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

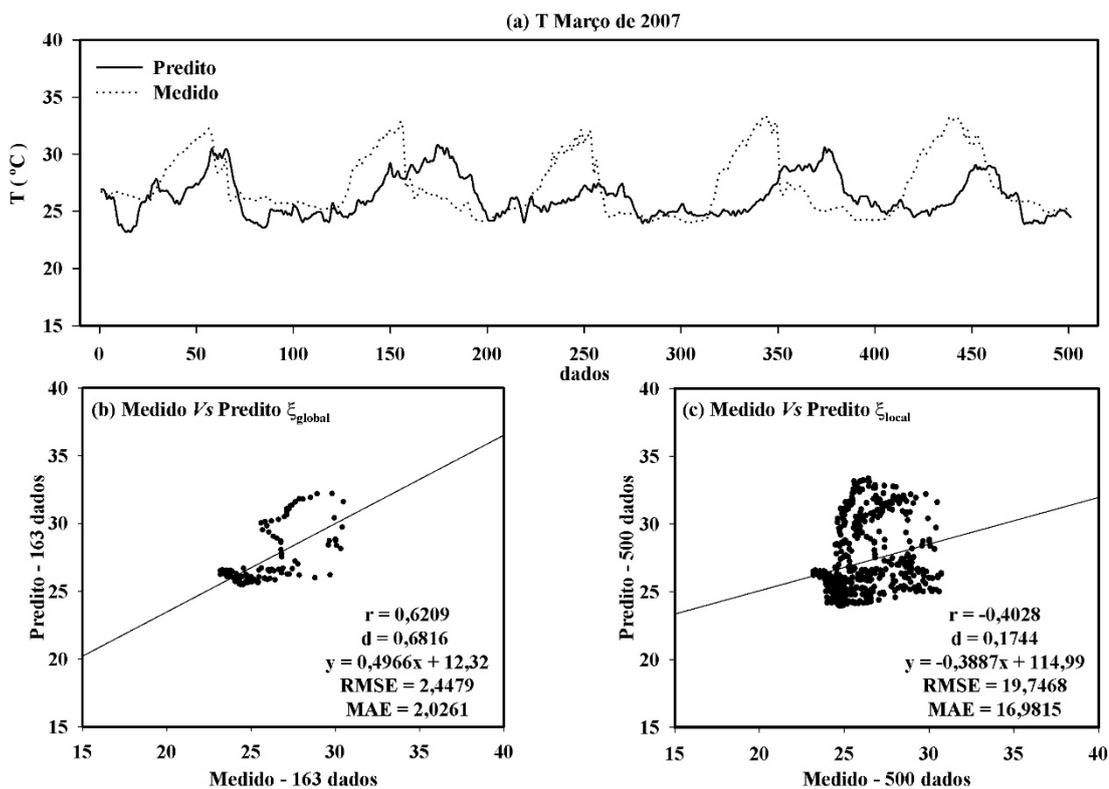


Figura 49. (a) Série temporal de T medida e predita, março de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

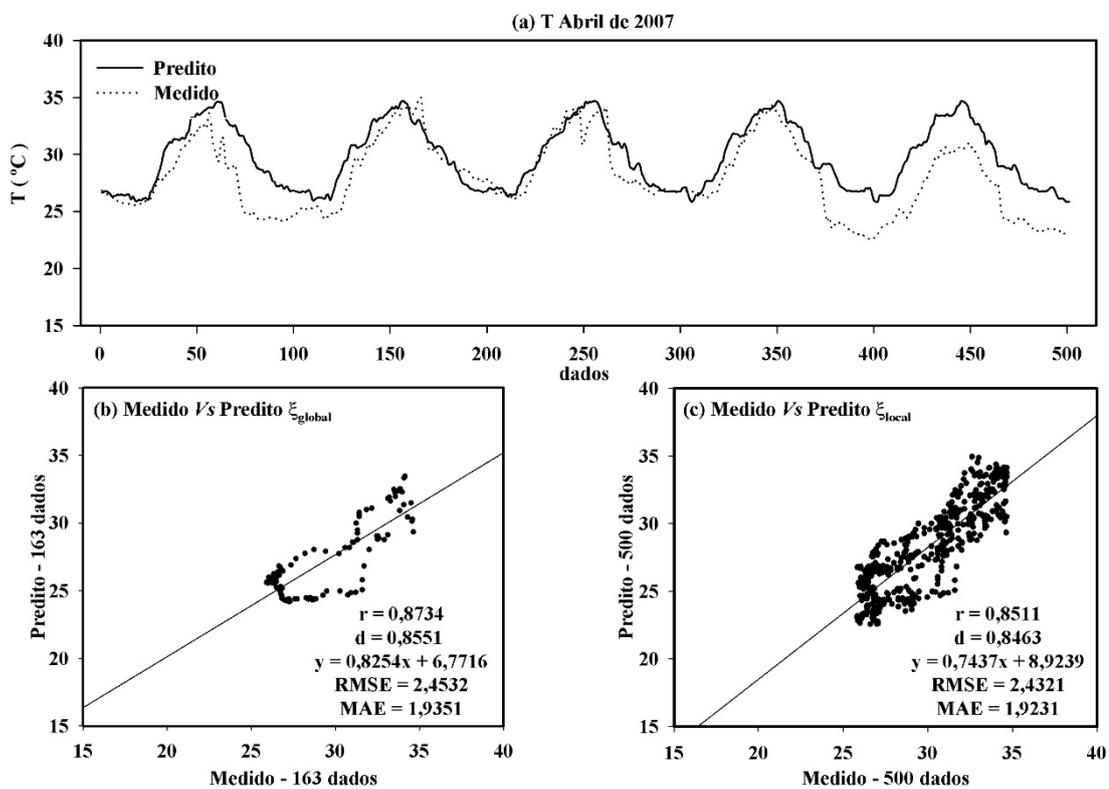


Figura 50. (a) Série temporal de T medida e predita, abril de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

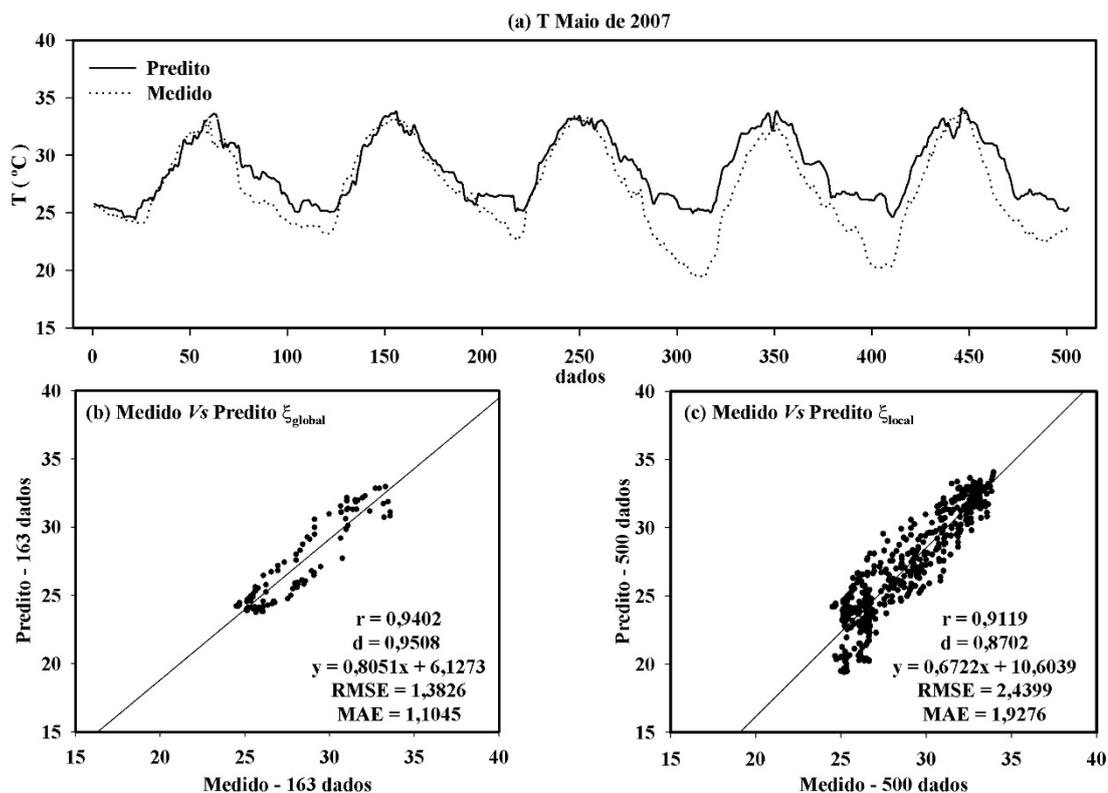


Figura 51. (a) Série temporal de T medida e predita, maio de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

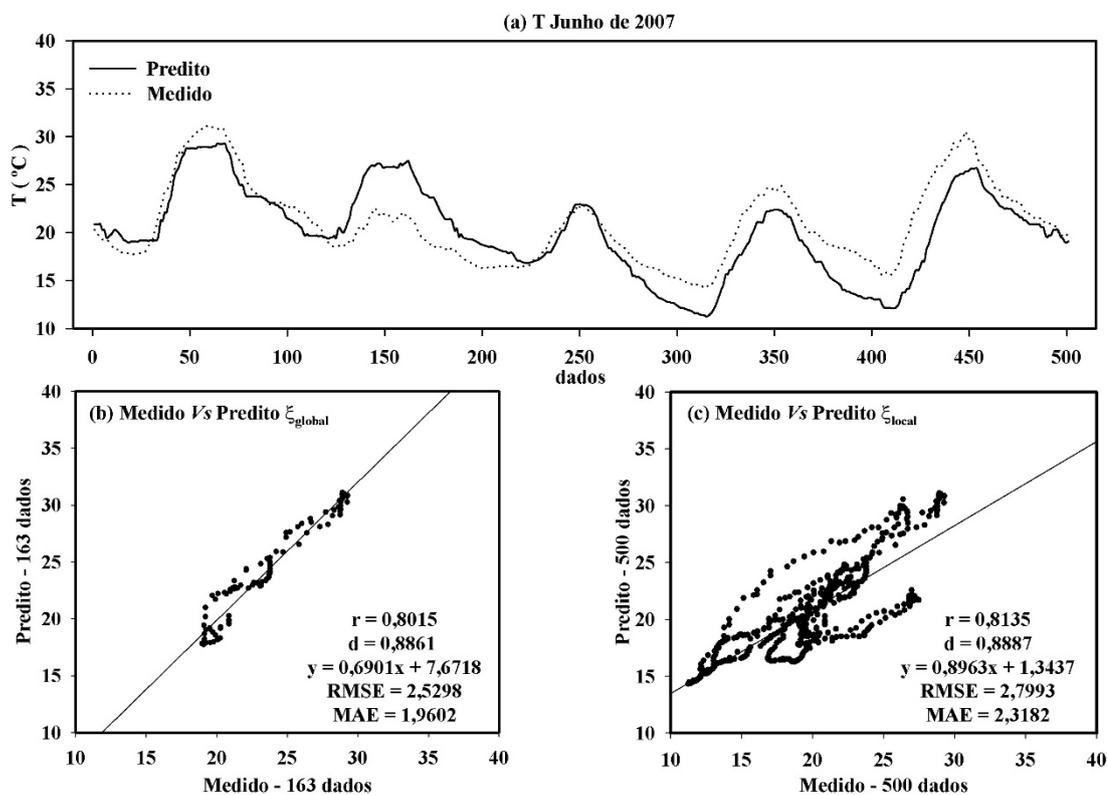


Figura 52. (a) Série temporal de T medida e predita, junho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

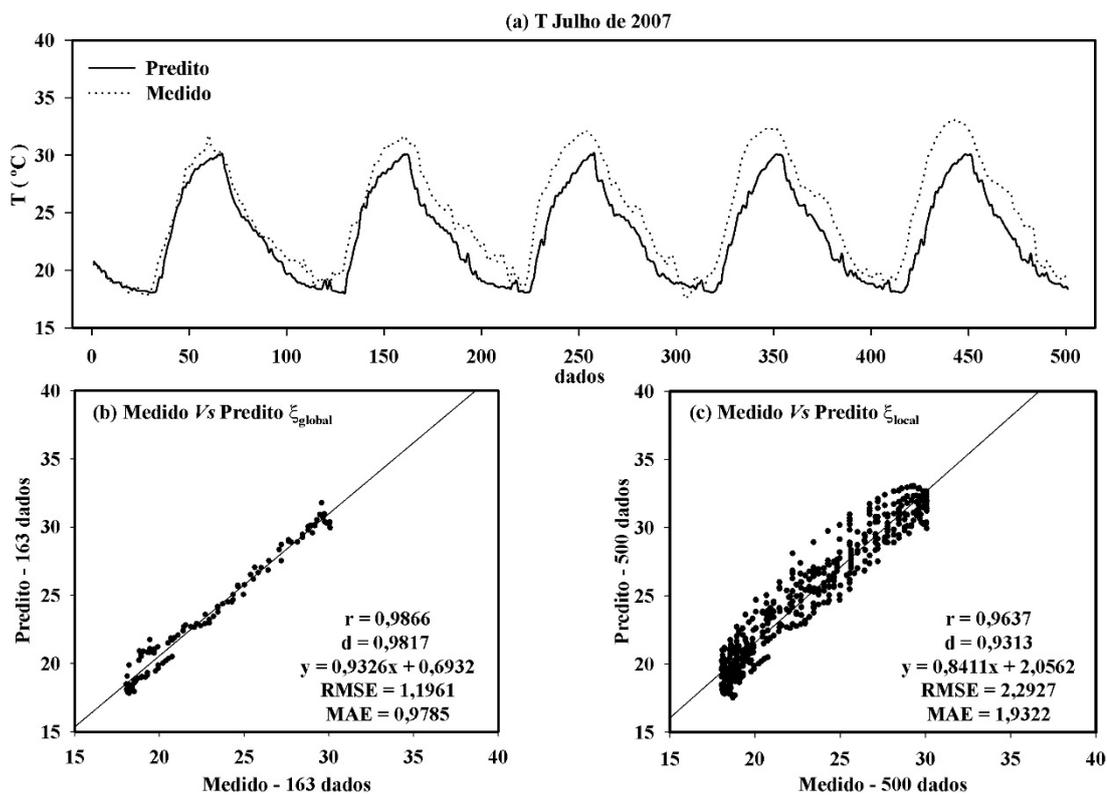


Figura 53. (a) Série temporal de T medida e predita, julho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

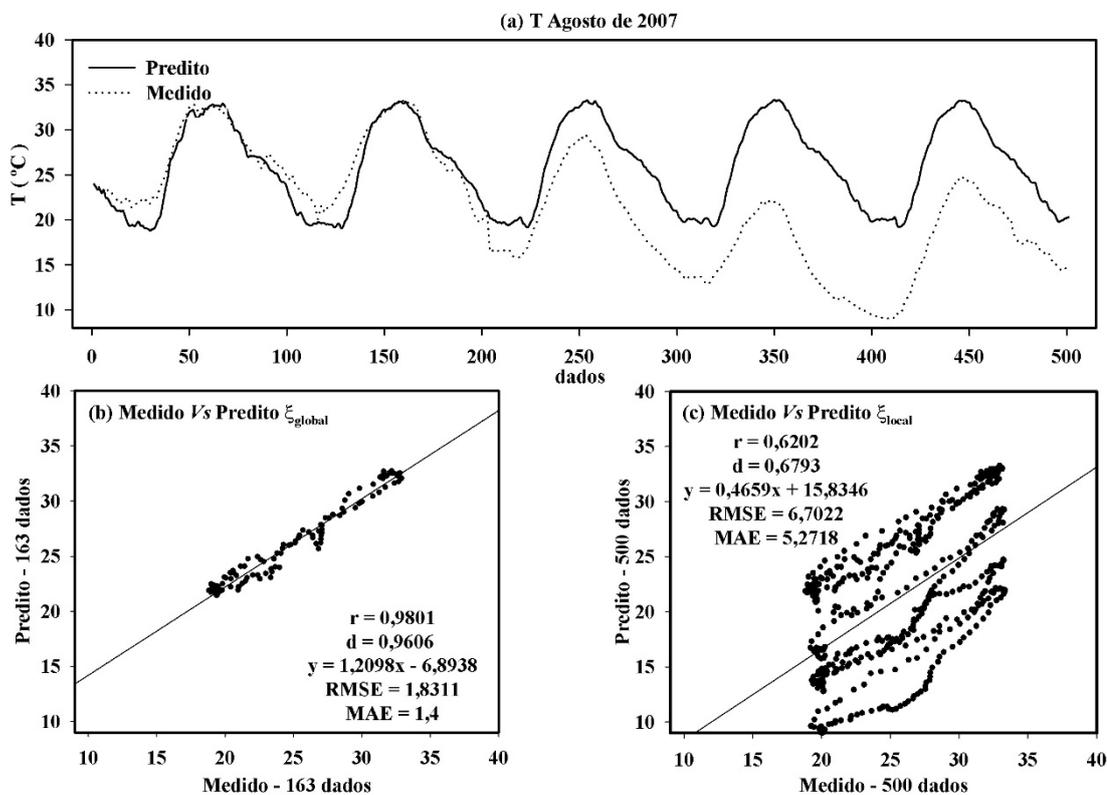


Figura 54. (a) Série temporal de T medida e predita, agosto de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

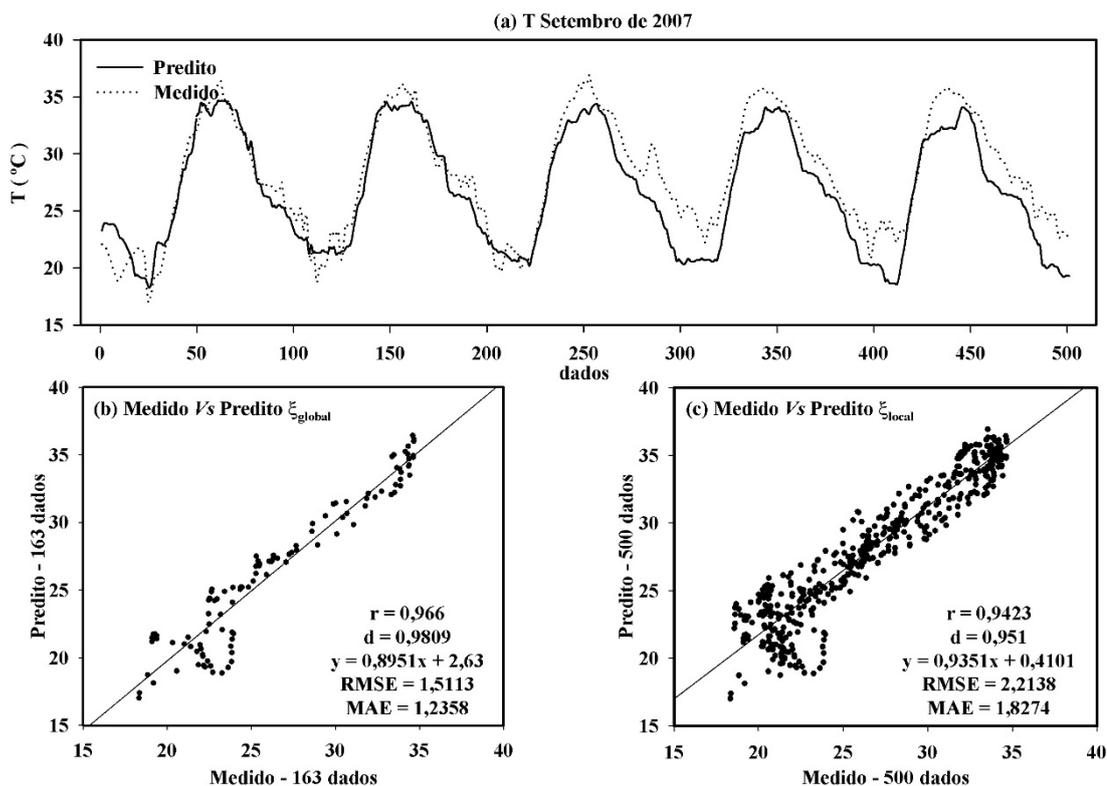


Figura 55. (a) Série temporal de T medida e predita, setembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

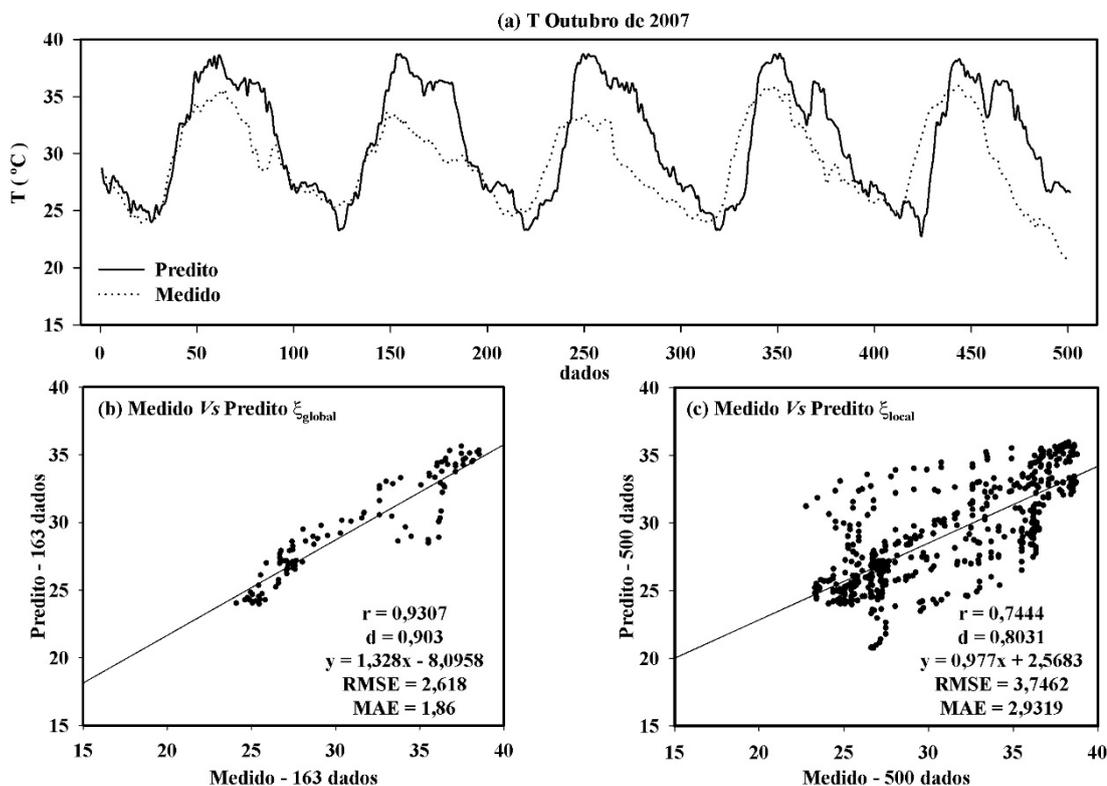


Figura 56. (a) Série temporal de T medida e predita, outubro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

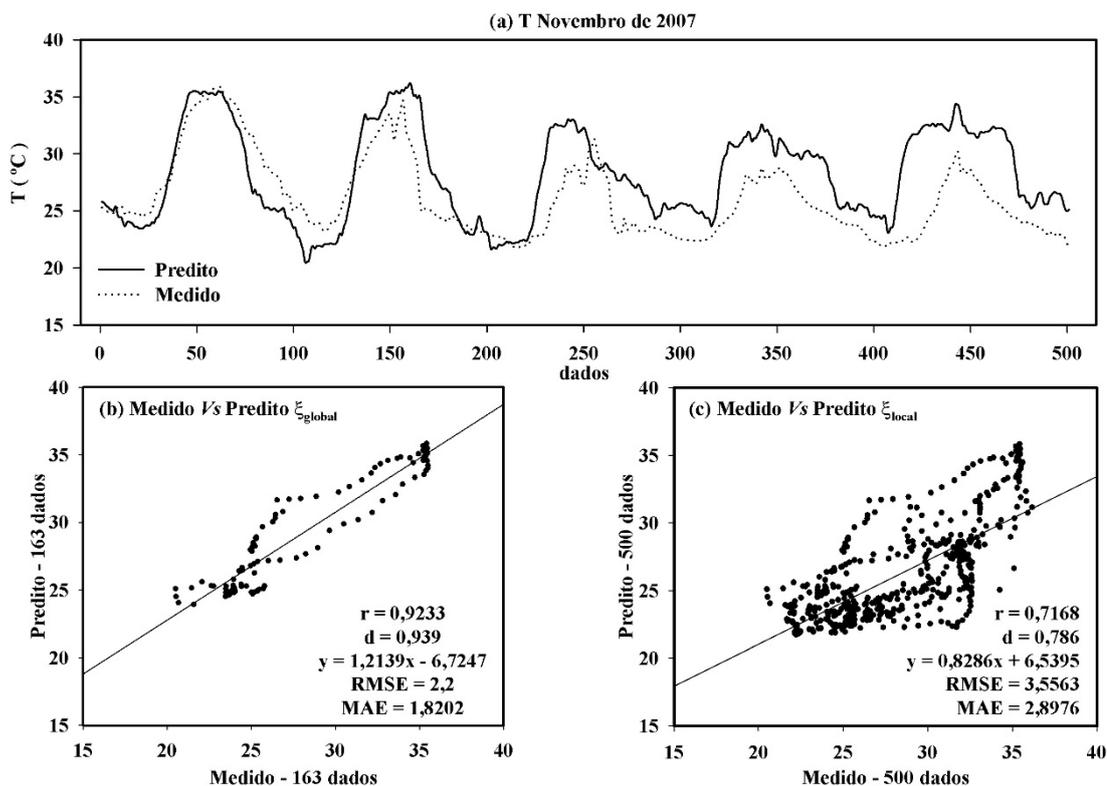


Figura 57. (a) Série temporal de T medida e predita, novembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

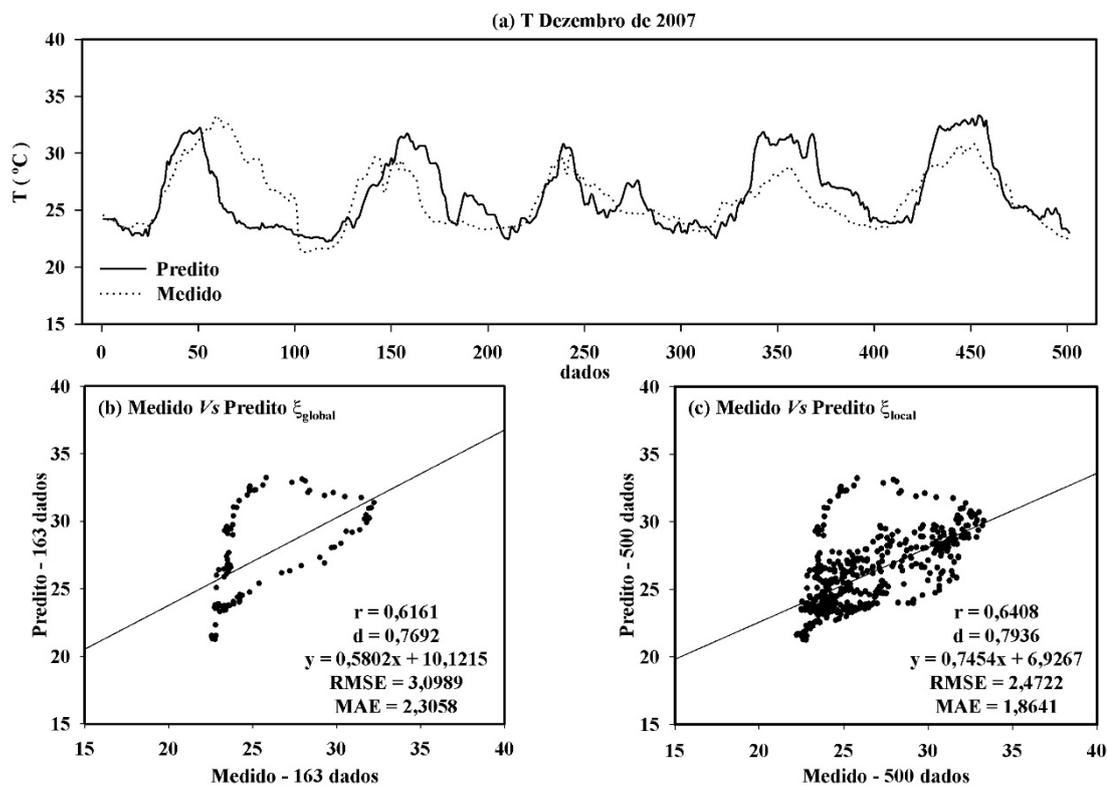


Figura 58. (a) Série temporal de T medida e predita, dezembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

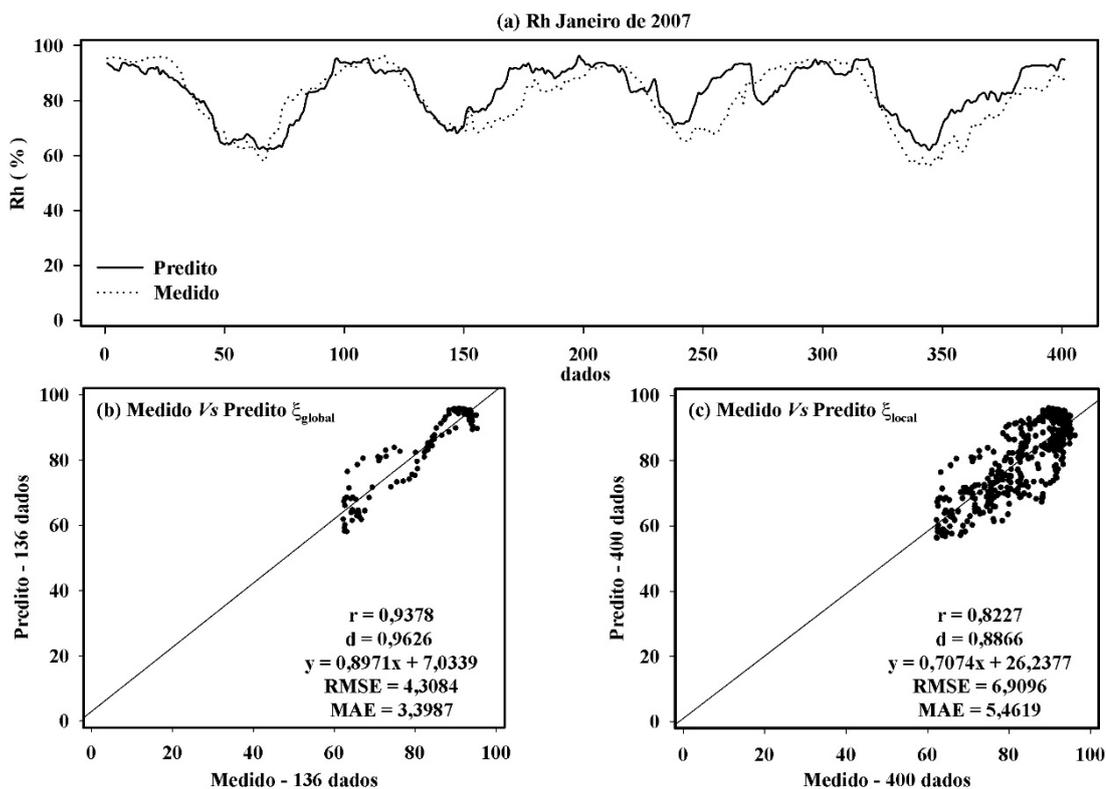


Figura 59. (a) Série temporal de Rh medida e predita, janeiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

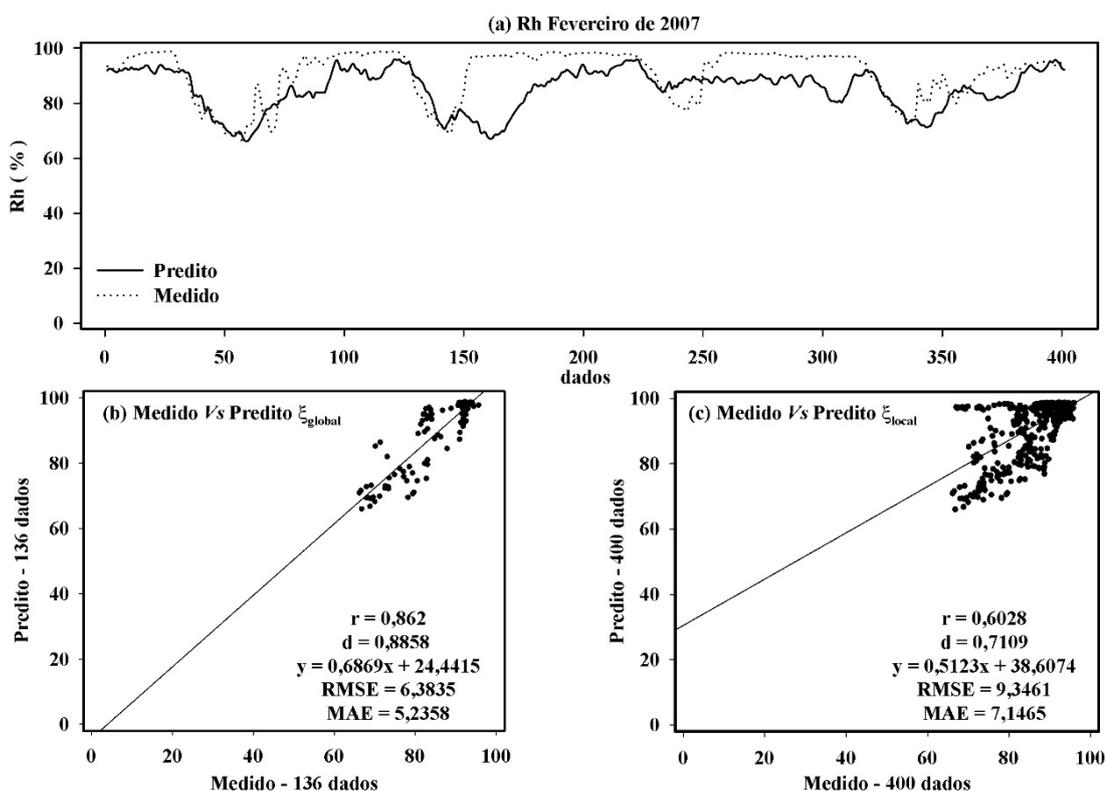


Figura 60. (a) Série temporal de Rh medida e predita, fevereiro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

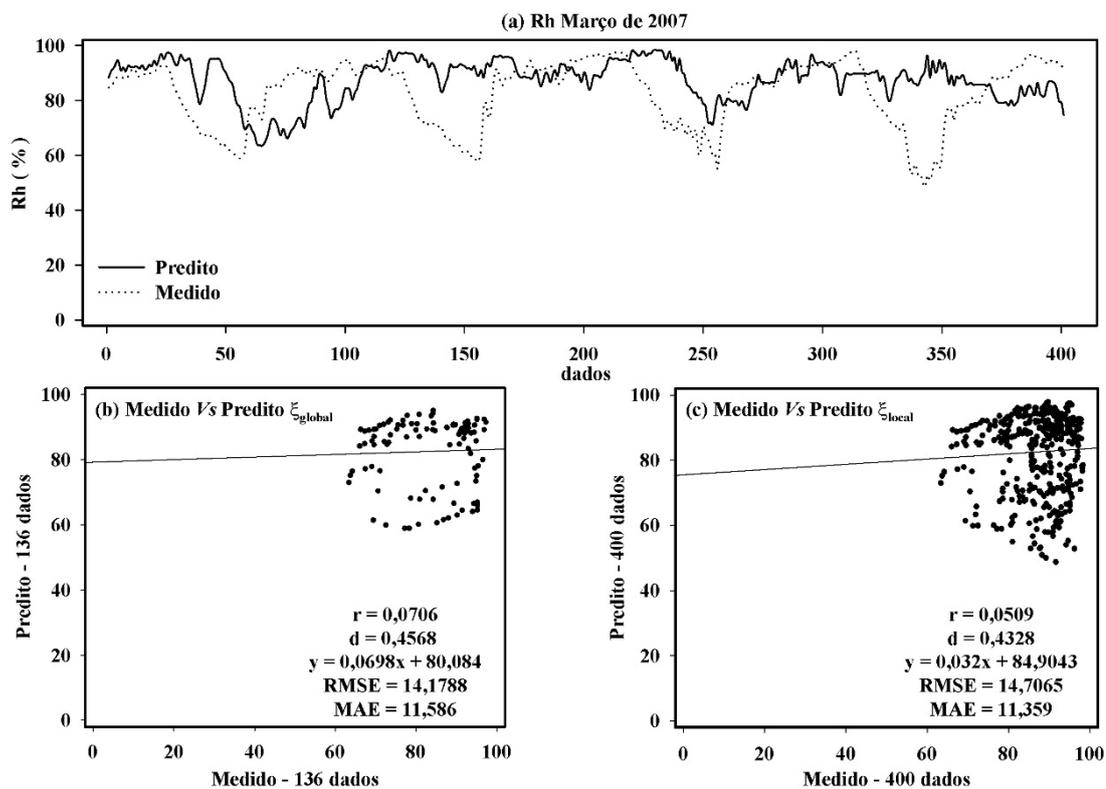


Figura 61. (a) Série temporal de Rh medida e predita, março de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

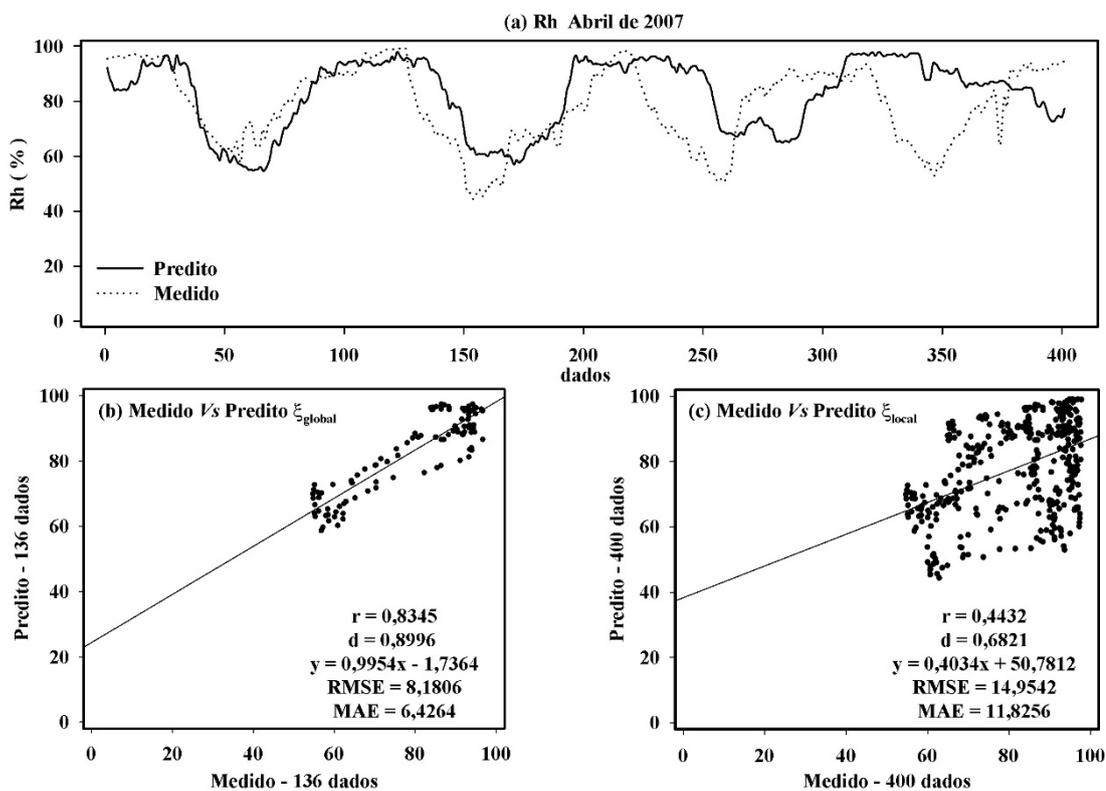


Figura 62. (a) Série temporal de Rh medida e predita, abril de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

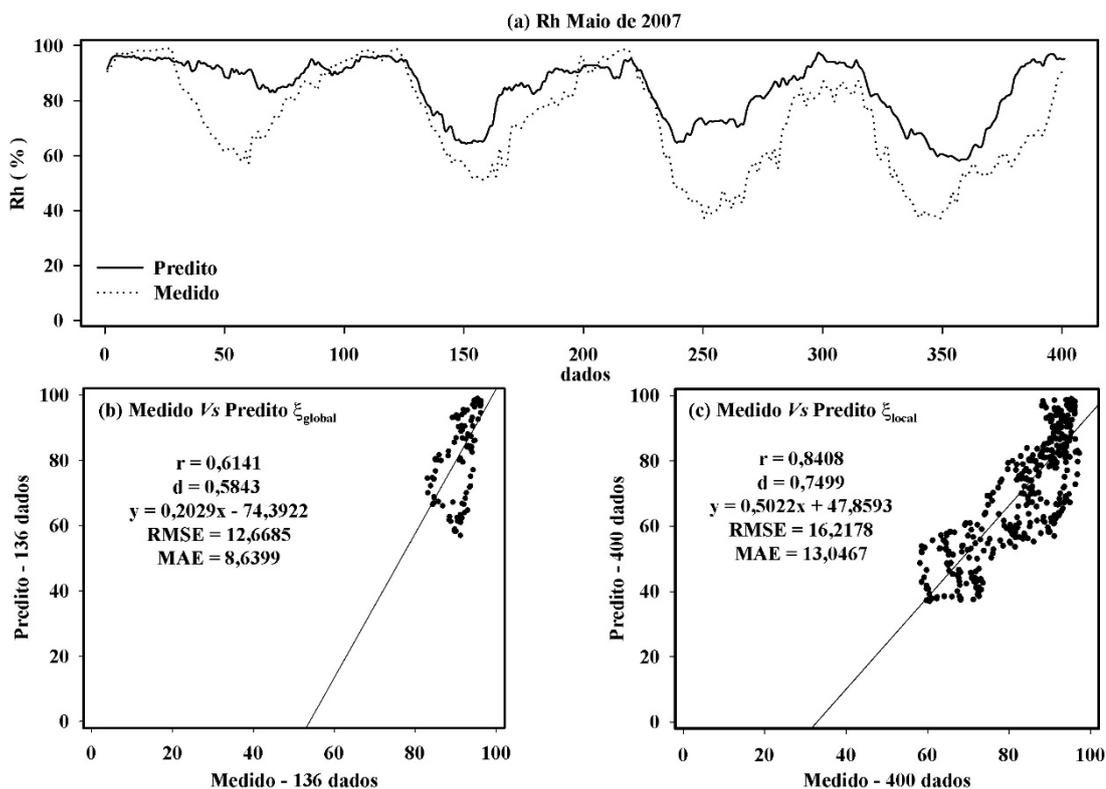


Figura 63. (a) Série temporal de Rh medida e predita, maio de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

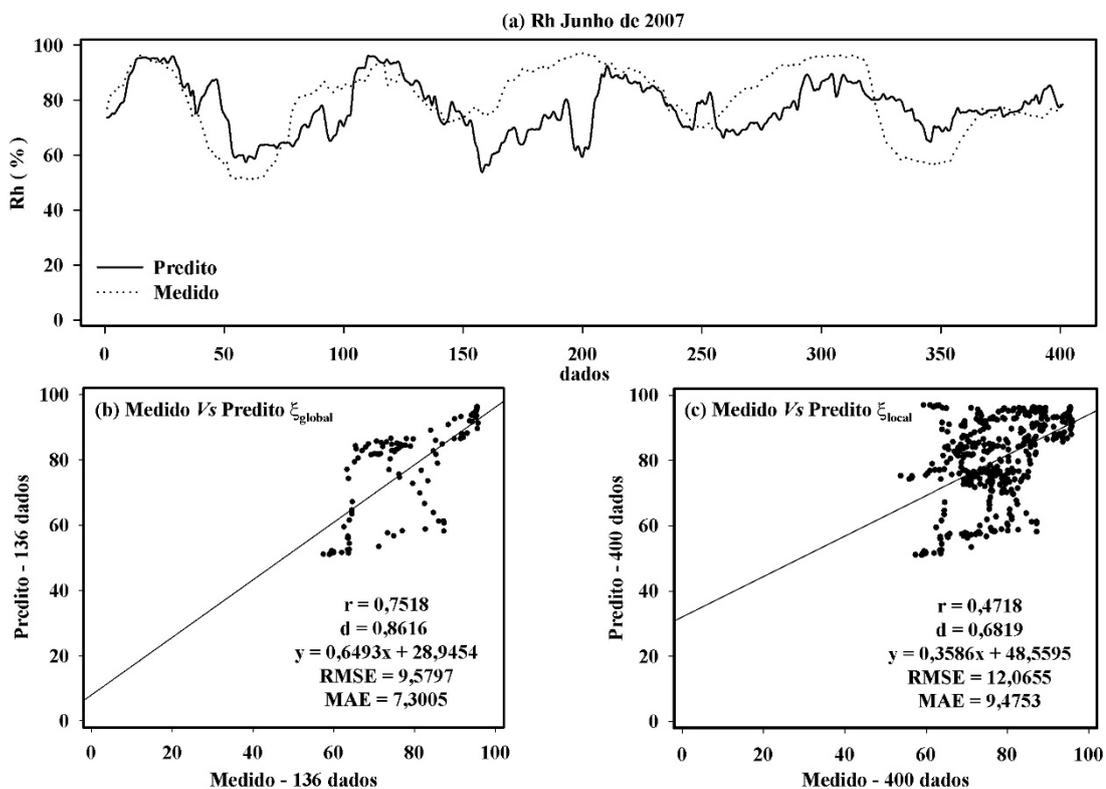


Figura 64. (a) Série temporal de Rh medida e predita, junho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

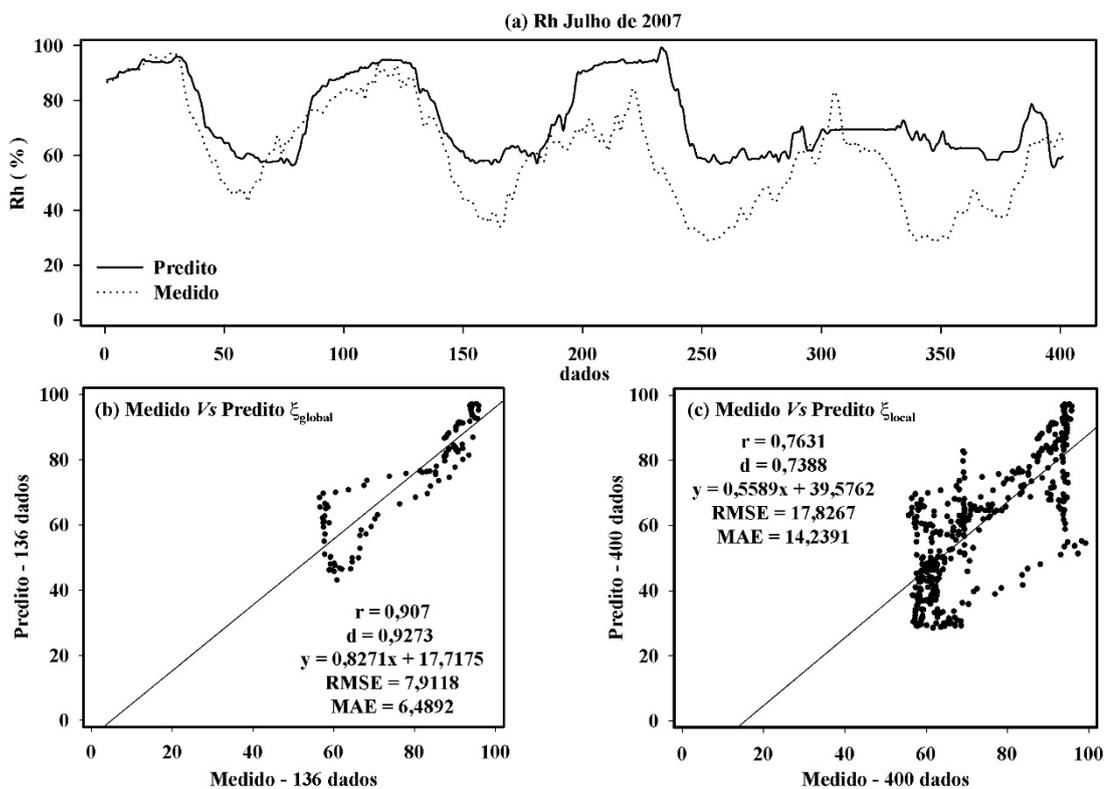


Figura 65. (a) Série temporal de Rh medida e predita, julho de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

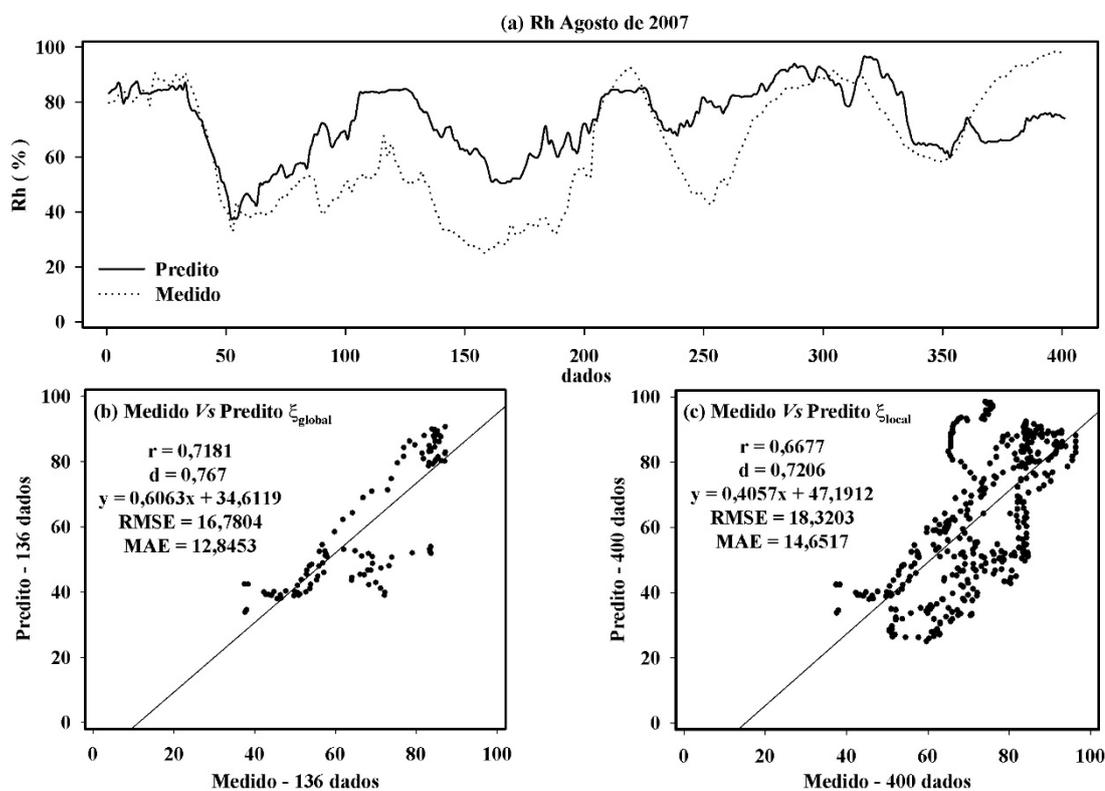


Figura 66. (a) Série temporal de Rh medida e predita, agosto de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

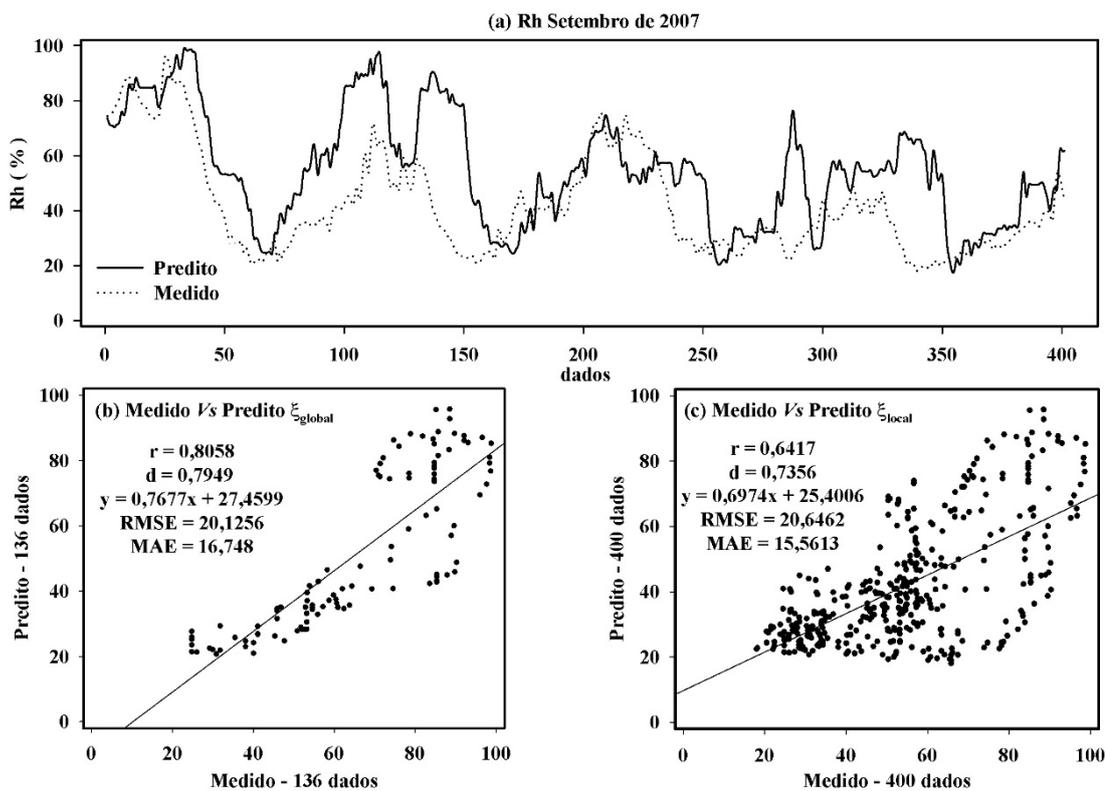


Figura 67. (a) Série temporal de Rh medida e predita, setembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

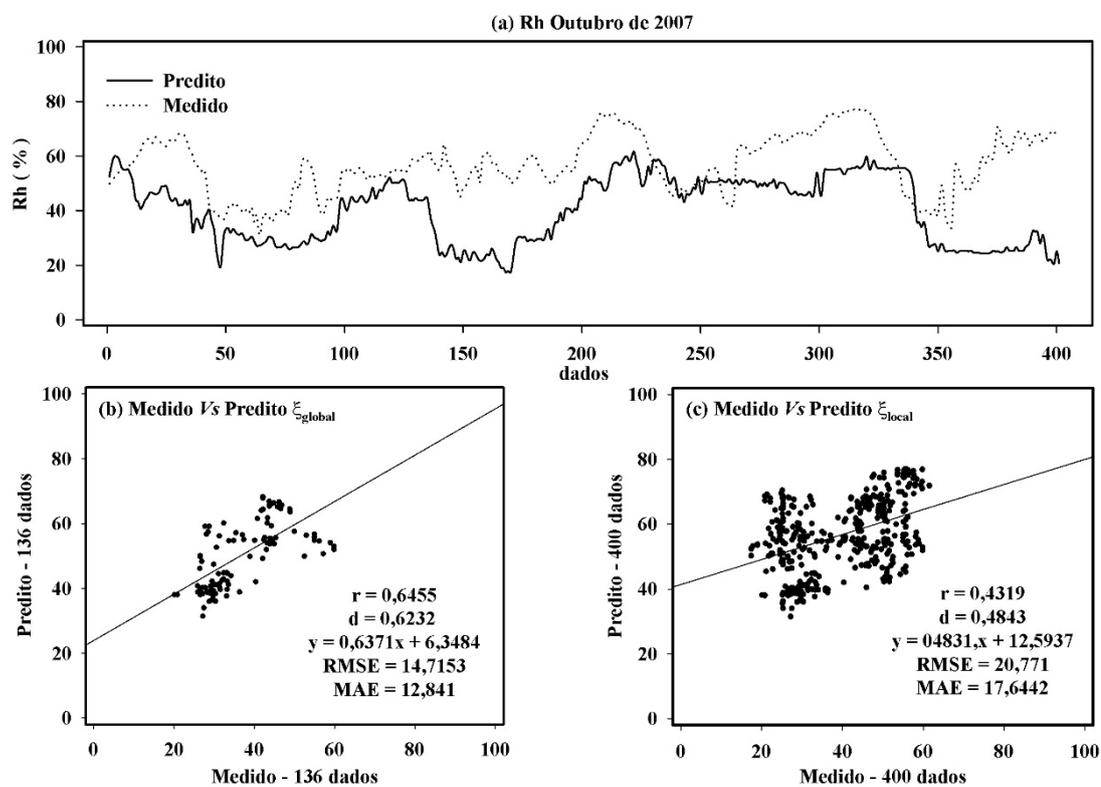


Figura 68. (a) Série temporal de Rh medida e predita, outubro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

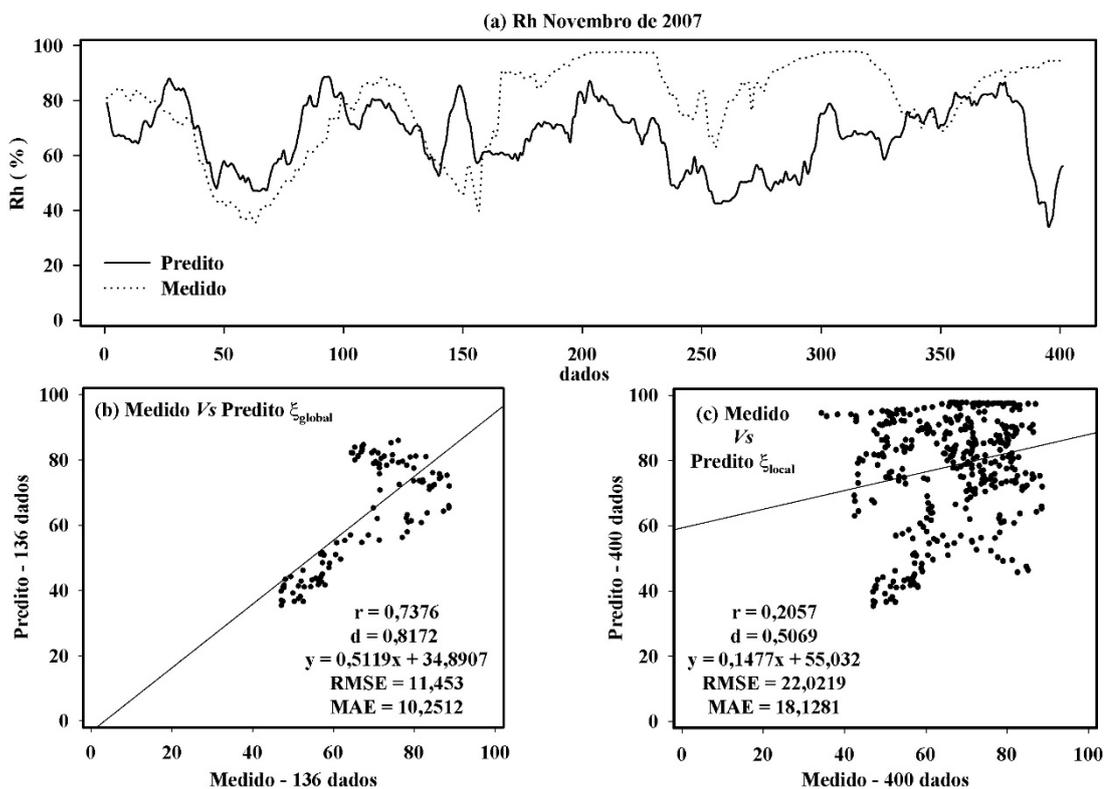


Figura 69. (a) Série temporal de Rh medida e predita, novembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

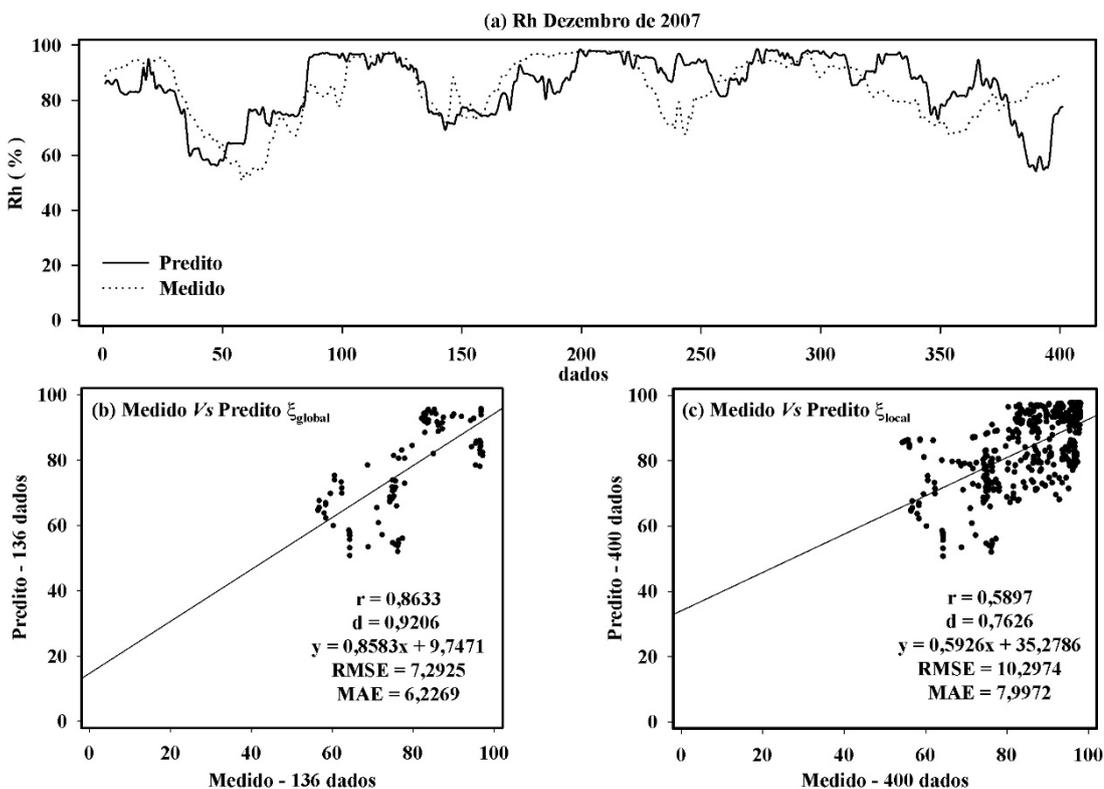


Figura 70. (a) Série temporal de Rh medida e predita, dezembro de 2007. Análise de erros para (b) ξ_{global} e (c) ξ_{local} .

Na Tabela 6 abaixo são apresentados os resultados das medidas de erro de previsão em termos de médias dos períodos seco e chuvoso, e quanto ao parâmetro ξ em global e local.

Tabela 6. Média e desvio padrão das Medidas de Erro de Predição das séries temporais micrometeorológicas quanto ao parâmetro ξ e a sazonalidade.

Medidas de Erro	ξ_{global}		ξ_{local}	
	seca (média)	chuva (média)	seca (média)	chuva (média)
r_{Rn}	0,99±0,01	0,95±0,03	0,98±0,01	0,91±0,01
d_{Rn}	0,99±0,01	0,96±0,02	0,99±0,01	0,94±0,05
$RMSE_{Rn}$	23,44±10,29	77,07±30,74	35,74±14,38	86,94±34,78
MAE_{Rn}	16,81±7,89	43,26±17,11	23,08±8,93	56,32±24,75
r_T	0,92±0,09	0,85±0,13	0,80±0,14	0,68±0,39
d_T	0,94±0,04	0,86±0,11	0,83±0,11	0,76±0,22
$RMSE_T$	1,85±0,54	2,18±0,68	3,93±1,97	4,51±5,43
MAE_T	1,44±0,41	1,71±0,53	3,17±1,49	3,73±4,72
r_{Rh}	0,79±0,08	0,71±0,25	0,63±0,12	0,51±0,25
d_{Rh}	0,85±0,07	0,77±0,17	0,71±0,02	0,66±0,14
$RMSE_{Rh}$	11,42±3,85	11,03±4,69	16,07±2,84	15,09±5,12
MAE_{Rh}	8,87±2,82	9,03±3,99	12,78±2,35	12,01±4,29

As séries temporais preditas versus medida da variável Rn obtiveram os melhores resultados de previsão. Os valores de r_{Rn} e d_{Rn} , para ξ_{global} e ξ_{local} se mantiveram próximos de 1 na seca e acima de 0,91 na chuva ambos, com erros em torno de 5% na seca e menores que 10% na chuva. O resultado de Rn é muito importante visto ser uma variável diretamente relacionada com entrada e saída de energia do sistema, implicando nesse saldo uma ligação direta com o aquecimento ou resfriamento desse sistema. O mês de março apresentou os piores resultados de Medidas de Erros de Predição visto o mês anterior (fevereiro) que é utilizado para se fazer a predição apresentar altos índices de chuvas e nebulosidade.

As séries temporais preditas da variável T obtiveram resultados relevantes. Os valores de r_T e d_T , para ξ_{global} se mantiveram em média acima de 0,92 na seca e acima de 0,85 na chuva; e para ξ_{local} os valores foram r_T e d_T acima de 0,80 na seca e acima de 0,68 na chuva. Ressalta-se também para esta série temporal, valores péssimos de previsão para o mês de março, que por sinal pesaram para baixar a média dos demais parâmetros. Excluindo-se o mês de março, que obteve péssima previsão, a média de r_T e d_T para ξ_{local} na chuva ficaria acima de 0,82. A

temperatura é uma variável muito importante no estudo ambiental, visto ser componente de diversas outras variáveis meteorológicas, uma boa previsão destas séries indica que outras mais podem ser bem modeladas. O que se soma ao fato de ser facilmente medida em numerosas estações meteorológicas.

Quanto às séries temporais preditas da variável Rh obtiveram resultados medianos. Os valores de r_{Rh} e d_{Rh} , para ξ_{global} se mantiveram próximos de 0,80 na seca e acima de 0,71 na chuva, e para ξ_{local} acima de 0,63 na seca e 0,51 na chuva. As predições de Rh foram as que apresentaram as menores correlações e exatidões e os maiores erros. Esta variável possui uma dinâmica sensível à variação de outras variáveis, principalmente as ligadas à circulação atmosférica global. Assim como Rn , o mês de março para Rh apresentou também para esta variável as piores previsões.

5. CONCLUSÃO

Três séries temporais micrometeorológicas de Saldo de Radiação, Temperatura do Ar e Umidade Relativa do Ar medidas no Pantanal Norte de Mato Grosso, Brasil foram analisadas e preditas por uma abordagem fundamentada na Teoria dos Sistemas Dinâmicos. As séries temporais não foram submetidas a nenhum tipo de filtragem. Os quatro anos de dados micrometeorológicos do Saldo de Radiação, da Temperatura do Ar e da Umidade Relativa do Ar foram testados em termos de não linearidade e obtiveram resultados positivos. O espaço de fase contendo o conjunto atrator associado a cada série temporal foi reconstruído por meio de defasagem temporal ($Rn_\tau = 24, T_\tau = 30$ e $Rh_\tau = 50$) e dimensão de imersão ($Rn_m = 6, T_m = 6$ e $Rh_m = 6$) respectivamente pelos métodos da Informação Mútua e Falsos Vizinhos Próximos. Visando extrair informações para a predição, foi feita a caracterização das variáveis segundo a análise de séries temporais não lineares, em termos qualitativos por Gráficos de Recorrência identificando na sazonalidade os períodos cíclicos e os não lineares. Em termos quantitativos, a Análise Quantitativa de Recorrência, em suas medidas de Razão de

Recorrência, Determinismo, Laminaridade e Entropia, forneceram a localização no tempo e a estimativa desses valores na série temporal esses períodos. Houve inversão de fase entre o saldo de radiação (maiores picos no período seco) e temperatura (maiores picos no período chuvoso). A humidade relativa apresentou tendência de comportamento errático.

Quanto à dinâmica, todas as séries temporais analisadas apresentaram maior Expoente de Lyapunov positivos, embora pequenos, caracterizando as dinâmicas como caóticas.

Quanto à geometria, os resultados sugerem a existência de uma dinâmica de baixa dimensão (Dimensão de Correlação) das séries temporais foi $D_{2(Rn_{global})} = 4,14 \pm 0,05$, $D_{2(T_{global})} = 3,93 \pm 0,03$ e $D_{2(Rh_{global})} = 4,15 \pm 0,02$, semelhante a valores encontrados na literatura.

Por fim é aplicado o método de Predição Não Linear Simples mês a mês para os doze meses do ano de 2007, de forma que foi utilizada uma série medida de um mês anterior para estimar uma série prevista referente ao mês seguinte, da qual são verificadas a correlação, a exatidão e os erros dentro do tempo estabelecido pelo parâmetro de previsão confiável.

Os resultados permitem afirmar que o método de predição não linear simples capturou a dinâmica geral das séries temporais micrometeorológicas medidas no Pantanal Mato-grossense. As séries temporais preditas são muito próximas das séries temporais medidas, sendo a mais próxima o saldo de radiação, em seguida a temperatura e por fim a umidade relativa do ar. As diferenças entre as séries medidas e as preditas em termos de correlação, exatidão e erros de predição aumentam no período chuvoso, e também aumentam na proporção que se aumenta o tempo futuro predito.

Desta forma, conclui-se que a abordagem por teoria dos sistemas dinâmicos para análise e predição de séries temporais não lineares se apresenta útil quando aplicadas em dados micrometeorológicos.

6. REFERÊNCIAS

ABARBANEL, H. D. I., BROW, R.; SIDOROWICH, J. J.; TSIMRING, L. S. The analysis of observed chaotic data in physical systems. **Review of Modern Physics**, v.65, n.4, p.1331-1392, 1993.

ABARBANEL, H. D. Tools for the analysis of chaotic data. **Annals of the New York Academy of Sciences**, v.808, n.1, p.1-17, 2006.

ALVES, F. S. M.; FISCH, G.; VENDRAME, I. F. Modificações do microclima e regime hidrológico devido ao desmatamento na Amazônia: um estudo de caso em Rondônia (RO), Brasil. **Acta Amazônica**, v.29, n.3, p.395-409, 1999.

ARIEIRA, J.; NUNES DA CUNHA, C. Fitossociologia de uma floresta inundável monodominante de *Vochysia divergens* Pohl (Vochysiaceae), no Pantanal Norte, MT, Brasil. **Acta Botanica Brasilica**, v.20, p.569-580, 2006.

ARYA, S. P. **Introduction to Micrometeorology**. San Diego, USA: Academic Press, 2001. 420p.

ASSAD, E.; PINTO, H. S. (Org.). **Aquecimento global e a nova geografia da produção agrícola no Brasil**. EMBRAPA-Empresa Brasileira de Pesquisa

Agropecuária. UNICAMP/CEPAGRI-Centro de Pesquisas Meteorológicas e Climáticas Aplicadas a Agricultura. 1. ed. São Paulo, Posigraf: 2008. 83p.

BAKER, G. L.; GOLLUB, J. P. **Chaotic dynamics: an introduction**. New York, USA: Cambridge University Press; 1996. 256p.

BASHARAT, A.; SHAH, M. Time Series Prediction by Chaotic Modeling of Nonlinear Dynamical Systems. **IEEE 12th International Conference on Computer Vision**. Kyoto, Japão: p.1941-1948, 2009.

BERNDTSSON, R.; JINNO, K.; KAWAMURA, A.; OLSSON, J.; XU, S. Dynamical systems theory applied to long-term temperature and precipitation time series. **Trends in Hydrology**, v.1, p.291-7, 1994.

BIUDES, M. S.; CAMPELO JUNIOR, J. H.; NOGUEIRA, J. S.; SANCHES, L. Estimativa do balanço de energia em cambarazal e pastagem no norte do Pantanal pelo método da razão de Bowen. **Revista Brasileira de Meteorologia**, v.24, n.2, p.135-143, 2009.

BIUDES, M. S.; MACHADO, N. G.; DANELICHEN, V. H. M.; SOUZA, M. C.; VOURLITIS, G. L.; NOGUEIRA, J. S. Ground and remote sensing-based measurements of leaf area index in a transitional forest and seasonal flooded forest in Brazil. **International Journal of Biometeorology**, v.58, n.224, p.1-13, 2013.

BIUDES, M. S.; NOGUEIRA, J. S.; DALMAGRO, H. J.; MACHADO, N. G.; DANELICHEN, V. H. M.; SOUZA, M. C. Mudança no microclima provocada pela conversão de uma floresta de cambará em pastagem no norte do Pantanal. **Revista de Ciências Agro-Ambientais**, v.10, p.61-68, 2012.

BRASIL, A. E.; ALVARENGA, S. M. **Relevo. in: Geografia do Brasil – Região Centro Oeste, volume 1**. Fundação Instituto Brasileiro de Geografia e Estatística. Diretoria de Geociências. Rio de Janeiro, 1989.

CAMPANHARO, A.S.L.O.; RAMOS, F. M.; MACAU, E. E. N.; ROSA, R. R.; BOLZAN, M. J. A.; SÁ, L. D. A. Searching chaos and coherent structures in the

atmospheric turbulence above the Amazon forest. **Philosophical Transactions of the Royal Society A**, v.366, p.579- 589, 2008.

CAPRA, F. A **Teia da Vida**. 10. ed. São Paulo: Cultrix, 2006. 256p.

CASDAGLI, M. Nonlinear prediction of chaotic time series. **Physica D**, v.35, p.335-356, 1989.

CHAKRABORTY, D.; ROY, T. K. Generation and prediction of self-similar processes by surrogates. **Fractals**, v.14, p.17-26, 2006.

CHAUDHURI, S. Predictability of chaos inherent in the occurrence of severe thunderstorms. **Advances in Complex Systems**, v.9, p.77-85, 2006.

COSTA, M. H.; PIRES, G. F. Effects of Amazon and Central Brazil deforestation scenarios on the duration of the dry season in the arc of deforestation. **International Journal of Climatology**, v.30, p.1970-1979, 2010.

DINIZ, G.; FONSECA, M.; JR CAMPELO, J. H. Análise harmônica do regime de precipitação em duas localidades da baixada cuiabana. **Biomatemática**, v.18, p.37-48, 2008.

ECKMANN, J. P.; KAMPHORST, S. O.; RUELLE, D. Recurrence plots of dynamical systems. **Europhysics Letter**, v.4, n.9, p.973-977, 1987.

ECKMANN, J. P.; RUELLE, D. Fundamental limitations for estimating dimensions and Liapunov Exponents in dynamical systems. **Physica D**; v.56, p.185-187, 1992.

FERREIRA, H. S. Dinâmica caótica em ecologia: avanços teóricos e metodológicos. **Neotropical Biology and Conservation**, v.4, n.3, p.125-132, 2009.

FIEDLER-FERRARA, N.; PRADO, C. P. C. **Caos: Uma Introdução**. São Paulo: Editora Edgard Blucher Ltda, 1994. 402 p.

FISCH, G. **Camada limite Amazônica: aspectos observacionais e de modelagem**. 1996. 171f. Tese (Doutorado em Meteorologia) Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

FOKEN, T. **Micrometeorology**. Berlin, Germany: Springer; 2008. 306p.

FRASER, A. M. Information and Entropy in Strange Attractors. **IEE Transactions on Information Theory**, v.35, n.2, p.245-262, 1989.

FRASER, A. M.; SWINNEY, H. L. Independent coordinates for strange attractors from mutual information. **Physical Review A**, v.33, n.2, p. 1134-1140, 1986.

GLEICK, J. **Caos: a criação de uma nova ciência**. 17. ed. Rio de Janeiro: Campus/Elsevier, 1989. 310p.

GOMES, A. G.; VARRIALE, M. C. **Modelagem de Ecossistemas: Uma Introdução**. Editora da Universidade Federal de Santa Maria: Santa Maria, 2004. 503p.

GRASSBERGER, P.; PROCACCIA I. Characterization of strange attractors. **The American Physical Society**, v.50, p.5, p.346-349, 1983.

HASENACK, H.; CORDEIRO, J. L. P.; HOFMANN, G. S. **O Clima da RPPN SESC-Pantanal**. Porto Alegre, UFRGS, 27 p., 2003.

HEGGER, R.; KANTZ, H. Pratical implementation of nonlinear time series methods: the TISEAN package. **Chaos**, v.9, n.2, p.413-435, 1999.

IBGE. **Estatística da Produção Agrícola**. Rio de Janeiro: IBGE. 2013(a). Acessível em www.ibge.gov.br.

IBGE. **Estatística da Produção Pecuária**. Rio de Janeiro: IBGE. 2013(b). Acessível em www.ibge.gov.br.

IBGE. **Mapa de Biomas do Brasil, primeira aproximação**. Rio de Janeiro: IBGE. 2004. Acessível em www.ibge.gov.br.

INMET. **Normais Climatológicas do Brasil 1961-1990**. (Org.) RAMOS, A. M. ; SANTOS, L. A. R. ; FORTES, L. T. G. 1. ed. Brasília: 2009. v. 1. 465p.

JARAMILLO, G. P.; PUENTE, C. E. Strange attractors in atmospheric boundary-layer turbulence. **Boundary-Layer Meteorology**, v.64, p.175-197, 1993.

JAYAWARDENA, A. W.; GURUNG, A. B. Noise reduction and prediction of hydrometeorological time series: dynamical systems approach vs. stochastic approach. **Journal of Hydrology**, v.228 p.242-64, 2000.

KANTZ, H. A robust method to estimate the maximal Lyapunov exponent of a time series, **Physics Letters A**, v.185, p.77-87, 1994.

KANTZ, H.; SCHREIBER, T. **Nonlinear Time Series Analysis**. Cambridge University Press: Cambridge, UK, 2004. 369 p.

KENNEL, M. B.; BROWN, R.; ABARBANEL, H. D. Determining embedding dimension for phase-space reconstruction using a geometrical construction. **Physical Review A**, v.45, n.6, p.3403-3411, 1992.

KOEBBE, M.; MAYER-KRESS, G. Use of recurrence plots in the analysis of time-series data, in: M. Casdagli, S. Eubank (Eds.), **Proceedings of SFI Studies in the Science of Complexity**, vol. XXI. Redwood City, Addison-Wesley, p.361-378, 1992.

KYOUNG, M. S.; KIM, H. S.; SIVALUMAR, B.; SINGH, V. P.; AHN, K. S. Dynamic characteristics of monthly rainfall in the Korean Peninsula under climate change. **Stochastic Environmental Research and Risk Assessment**, v.25, p.613-625, 2011.

LAPOLA, D. M.; SCHALDACH, R.; ALCAMO, J. Impacts of climate change and the end of deforestation on land use in the Brazilian Legal Amazon. **Earth Interactions**, v.15, n.16, p.1-19, 2011.

LEWIS, S. L.; BRANDO, P. M.; PHILLIPS, O. L.; VAN DER HEIJDEN, G. M. F.; NEPSTAD, D. The 2010 Amazon Drought. **Science**, v.331, p.554, 2011.

LORENZ, E. N. Deterministic nonperiodic flow. **Journal of Atmospheric Sciences**, v.20, p.130-141, 1963.

LORENZ, E. N. Dimension of weather and climate attractors. **Letters to Nature**, v.353, p.241-244, 1991.

MARWAN, N.; ROMANO, M. C.; THIEL, M.; KURTHS, J. Recurrence plots for the analysis of complex systems. **Physics Reports**, v. 438, p. 237-329, 2007.

MARWAN, N.; WESSEL, N.; MEYERFELDT, U.; SCHIRDEWAN, A.; KURTHS, J. Recurrence plot based measures of complexity and its application to heart rate variability data. **Physical Review E**, v.66, p.026702(1-8), 2002.

McCLAIN, M. E. **The Ecohydrology of South American Rivers and Wetlands**. IAHS Press: Wallingford, UK. 2002. 209p.

MELLO, G. J. ; GOMES, R. S. R.; BIUDES, M. S.; DANELICHEN, V. H. M.; SOUZA, M. C. Teste de não linearidade de séries temporais micrometeorológicas. In: José de Souza Nogueira; Erondina Azevedo de Lima. (Org.). **Coletânea Física Ambiental II**. 1. ed. São Paulo: Baraúna, 2012b.

MELLO, G. J.; GOMES, R. S. R.; BIUDES, M. S.; DANELICHEN, V. H. M.; MACHADO, N. G. Expoente de Lyapunov de séries de temperatura do Pantanal Norte. In: José de Souza Nogueira; Erondina Azevedo de Lima. (Org.). **Coletânea Física Ambiental II**. 1. ed. São Paulo: Baraúna, 2012a.

MELLO, G. J.; GOMES, R. S. R.; SILVEIRA, S. W. G.; BIUDES, M. S.; PAULO, S. R. Gráficos de recorrência do balanço de radiação no Pantanal Norte. In: José de Souza Nogueira; Erondina Azevedo de Lima. (Org.). **Coletânea Física Ambiental I**. 1. ed. São Paulo: Baraúna, 2011.

MELLO, G. J.; PAULO, I. J. C.; PAULO, S. R.; GOMES, R. S. R.; MACHADO, N. G.; NOGUEIRA, J. S.; BIUDES, M. S. Dimensão fractal de séries temporais medidas acima do dossel de floresta no Pantanal Mato-grossense. **Revista Brasileira de Climatologia**, v.12, p.xx-xx, 2013b. (no prelo)

MELLO, G. J.; SILVEIRA, S. W. G.; GOMES, R. S. R.; MUSIS, C. R.; BIUDES, M. S.; PAULO, S. R. Análise sazonal da complexidade do saldo de radiação no Pantanal. **Revista Ciência e Natura**, v.35, p.86-97, 2013a.

MIKSOVSKY, J.; RAIDL, A. Testing for nonlinearity in European climatic time series by the method of surrogate data. **Theoretical and Applied Climatology**, v.83, p.21-33, 2005.

MILLÁN, H.; GHANBARIAN-ALAVIJEH, B.; GARCÍA-FORNARIS, I. Nonlinear dynamics of mean daily temperature and dewpoint time series at Babolsar, Iran, 1961-2005. **Atmospheric Research**, v.98, p.89-101, 2010.

MILLÁN, H.; KALAUZI, A.; LLERENA, G.; SUCOSHAÑAY J.; PIEDRA, D. Meteorological complexity in the Amazonian area of Ecuador: An approach based on dynamical system theory. **Ecological Complexity**, v.6, p.278-285, 2009.

MINDLIN, G. M.; GILMORE, R. Topological analysis and synthesis of chaotic time series. **Physica D**, v.58, p.229-242, 1992.

MOON, F. C. **Chaotic vibrations: an introduction for applied scientist and engineers**. New Jersey: John Wiley & Sons, Inc., 2004. 309 p.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. 2. ed. São Paulo: Edgard Blücher, 2006. 538p.

MOTTA, R. S.; HARGRAVE, J.; LUEDEMANN, G.; GUTIERREZ, M. B. S. **Mudança do Clima no Brasil: aspectos econômicos, sociais e regulatórios**. Secretaria de Assuntos Estratégicos - SAE. Instituto de Pesquisa Econômica Aplicada – IPEA: Brasília, DF, 2011. 438p.

NICOLIS, G.; PRIGOGINE, I. **Exploring complexity: an introduction**. W. H. Freeman and Company: Nova York, USA, 1998. 312p.

NOBRE, C. A. et al. Observations of the atmospheric boundary layer in Rondônia. In: GASH, J. H. C. et al. (Eds.) **Amazonian Deforestation and Climate**. J. M. Wiley and Sons, 1996. p. 413-424.

NUNES DA CUNHA, C.; JUNK, W. J. Year-to-year changes in water level drive the of *Vochysia divergens* in Pantanal glassland. **Applied Vegetation Science**, v.7, p.103-110, 2004.

OSBORNE A. R.; PROVENZALE A. Finite correlation dimension for stochastic systems with power-law spectra. **Physica D**, v.35, n.3, p.357-381, 1989.

OSIPOV, A. I. **Caos y auto organización**. Moscou: URSS, 2003. 148p.

OTT, E. **Chaos in dynamical systems**. Cambridge: Cambridge University Press, 1993. 385 p.

PACKARD, N. H.; CRUTCHFIELD, J. P.; FARMER, J. D.; SHAW, R. S. Geometry from a Time Series. **Physical Review Letters**, v.45, n.9, p.712-716, 1980.

PICOLI, F. Do Extrativismo ao Agronegócio das Monoculturas de Mercado na Amazônia Norte Mato-Grossense. **Revista Brasileira de Estudos Latino-Americano**, v.1, n.2, p.298-303, 2011.

PICOLI, F. **O capital e a devastação da Amazônia**. 1. ed. São Paulo: Ed. Expressão Popular, 2006. 255p.

PINTO, E. G. F.; SAVI, M. A. Nonlinear prediction of time series obtained from an experimental pendulum. **Current Topics in Acoustical Research - Research Trends**, v.3, p.151-162, 2003.

POINCARÉ, H. Sur la probleme des trois corps et les équations de la dynamique, **Acta Mathematica**, v.13, p.1-271, 1890.

PRIANTE FILHO, N.; VOURLITIS, G. L.; HAYASHI, M. M. S.; NOGUEIRA, J. S.; NUNES, P. C.; SANCHES, L.; COUTO, E. G.; HOEGER, W.; RAITER, F.; TRIENWEILER, L. J.; MIRANDA, E. J.; PRIANTE, P. C.; PEREIRA, L. C.; BIUDES, M. S. Comparison of the mass and energy exchange of a pasture and a mature transitional tropical forest of the southern Amazon basin during the wet-dry season transition. **Global Change Biology**, v.10, p.863-876, 2004.

PRICHARD, D.; THEILER, J. Generalized redundancies for time series analysis. **Physica D**, v.84, p.476-493, 1995.

PROVENZALE, A.; SMITH, L. A.; VIO, R.; MUTANTE, G. Distinguishing between low-dimensional dynamics and randomness in measured time series. **Physica D**, v.58, p.31-49, 1992.

REICHARDT, K; TIMM, L. C. **Solo, Planta e Atmosfera: Conceitos, Processos e Aplicações**. 1ª ed. Barueri, SP: Manole, 2008. 478 p.

ROSENSTEIN, M. T.; COLLINS, J. J.; DE LUCA, C. J. A practical method for calculating largest Lyapunov exponents from small data sets. **Physica D**, v.65, p.117-134, 1993.

ROULSTON, M. S. Estimating the errors on measured entropy and mutual information. **Physica D**, v.125, p.285-294, 1999.

RUELLE, D., TAKENS, F. On the nature of turbulence. **Communications in Mathematical Physics**, v.20, p.167-192, 1971.

SALATI, E; SANTOS, A. A.; KLABIN, I. Temas ambientais relevantes. **Estudos Avançados**, v.20, n.56, p.107-127, 2006.

SAVI, M. A. **Dinâmica Não Linear e Caos**. Rio de Janeiro: Editora E-papers, 2006. 304 p.

SCHREIBER, T. Interdisciplinary application of nonlinear time series methods. **Physics Reports**, v.308, p.1-64, 1999.

SCHREIBER, T.; SCHMITZ, A. Improved surrogate data for nonlinearity tests. **Physical Review Letters**, v.77, p.635-638, 1996.

SCHREIBER, T.; SCHMITZ, A. Surrogate times series. **Physica D**, v.142, p.346-382, 2000.

SIVAKUMAR, B.; LIONG, S. Y.; LIAW, C. Y.; PHOON, K. K. Singapore rainfall behavior: chaotic? **Journal of Hydrologic Engineering**. v.4, p.38-48, 1999.

SOUZA, C. A.; CUNHA, S. B. Dinâmica das águas no Pantanal Mato-Grossense Pantanal. Mato-grossense. **Revista Ação Ambiental**, v.6, n.26, 2004.

SOUZA, J. B.; LANI, J. L. Solos do Pantanal Mato-grossense: Ambientes, tipos e características gerais. **Revista Ação Ambiental**, v.6, n.26, p. 24-27, 2004.

TAKENS, F. Detecting strange attractors in turbulence, in *Dynamical Systems and Turbulence*, **Lecture Notes in Mathematics**, eds. Rand, D. & Young, L. S. Springer-Verlag, Berlin, v.898, p.366-381, 1981.

THEILER, J.; EUBANK, S.; LONGTIN, A.; GALDRIKIAN, B.; FARMER, J. D. Testing for nonlinearity in time series: the method of surrogate data. **Physica D**, v.58, p.77-94, 1992.

THEILER, J.; S. LINSAY, P. S.; M. RUBIN, D. M. Detecting Nonlinearity in Data with Long Coherence Times. In: **Predicting the Future and Understand the Past**. Eds. WEIGEND, A. S.; GERSHENFELD. N. A. Santa Fé Institute Studies in the Sciences of Complexity, Proc. V. XVII, Addison-Wesley, 1993.

THIEL, M.; ROMANO, M. C.; KURTHS, J. How much information is contained in a recurrence plot? **Physics Letters A**, v.330, n.5, p.343-349, 2004.

TONG, H. Birth of the threshold time series model. **Statistica Sinica**, v.17, p.8-14, 2007.

TONG, H. Discussion of 'An analysis of global warming in the Alpine region based on nonlinear nonstationary time series models' by Battaglia and Protopapas. **Statistical Methods & Applications**, v.21, n.3, p.335-339, 2012.

TONG, H. **Threshold models in nonlinear time series analysis**. Lectures Notes in Statistics, vol. 21, Springer, New York, 1983.

TONG, H. Threshold models in time series analysis - 30 years on. **Statistics and Its Interface**, v.4, p.107-136, 2011.

TSONIS, A. A. The impact of nonlinear dynamics in the atmospheric sciences. **International Journal of Bifurcation and Chaos**, v.11, n.4, p.881-902, 2001.

VARILOVA, Z.; ZVELEBIL, J.; MILAN, P. Complex system approach to interpretation of monitoring time series: two case histories from NW Bohemia. **Landslides Springer-Verlag**, v.11, p.207-220, 2011.

VAŘILOVÁ, Z.; ZVELEBIL, J.; PALUŠ, M. Complex system approach to interpretation of monitoring time series: two case histories from NW Bohemia **Landslides**, v.8, p.207-220, 2011.

VIDAL, L. A. **Estudo da dinâmica de variáveis microclimatológicas da estação meteorológica de superfície do destacamento de controle do espaço aéreo de Cuiabá**. Cuiabá, 2009. 65p. Dissertação (Mestrado em Física Ambiental) - Instituto de Física, Universidade Federal de Mato Grosso.

VILA DA SILVA, J. S.; ABDON, M. M. Delimitação do Pantanal brasileiro e suas sub-regiões. **Pesquisa Agropecuária Brasileira**, v.33, Número Especial, p.1703-1711, 1998.

VIOLA, F. M.; PAIVA, S. L. D.; SAVI, M. A. Analysis of the global warming dynamics from temperature time series. **Ecological Modelling**, v.221, p.1964-1978, 2010.

VOURLITIS, G. L.; NOGUEIRA, J. S.; LOBO, F. A.; PAULO, S. R.; DIAS, C. A. A.; PINTO JÚNIOR, O. B.; ANDRADE, N. L. R. Energy balance and canopy conductance of a tropical semi-deciduous forest of the southern Amazon Basin. **Water Resources Research**, v.44, p.1-14, 2008.

VOURLITIS, G. L.; PRIANTE FILHO, N.; HAYASHI, M. M. S.; NOGUEIRA, J. S.; CASEIRO, F.; CAMPELO JÚNIOR, J. H. Seasonal variations in the evapotranspiration of a transitional tropical forest of Mato Grosso, Brazil. **Water Resources Research**, v.38, n.6, p.1094-1104, 2002.

WALLACE, J. M.; HOBBS, P. V. **Atmospheric science - an introductory survey**. 2. ed. Canada: Academic Press, 2006. 483p.

WEBBER Jr., C. L.; ZBILUT, J. P. Dynamical assessment of physiological systems and states using recurrence plot strategies. **Journal of Applied Physiology**, v.76, p.965-973, 1994.

WEBBER, C.L., Jr., ZBILUT, J.P. Recurrence quantification analysis of nonlinear dynamical systems. In: **Tutorials in contemporary nonlinear methods for the behavioral sciences**. Eds RILEY, M.A.; Van ORDEN, G. Capítulo 2, p.26-94, 2005. (Acesso em agosto de 2013: <http://www.nsf.gov/sbe/bcs/pac/nmbs/nmbs.pdf>)

WEIGEND, A. S.; N. A. GERSHENFELD (Eds.). **Time Series Prediction: Forecasting the Future and Understanding the Past**. Santa Fe Institute Studies in the Sciences of Complexity XV; Proceedings of the NATO Advanced Research Workshop on Comparative Time Series Analysis. Santa Fe, Addison-Wesley: 1994.

WILLMOTT, C. J. Some comments on the evaluation of model performance. **Bulletin American Meteorological Society**, v.63, n.11, p.1309-1313, 1982.

WRIGHT, I. R.; NOBRE, C. A.; TOMASELLA, J.; ROCHA, H.R.; ROBERTS, J.M.; VERTAMATTI, E.; CULF, A.D.; ALVALÁ, R.C.; HODNETT, M.G.; UBARANA, V. Towards a GCM surface parameterization for Amazonia. In: GASH, J. H. C.; NOBRE, C. A.; ROBERTS, J. M.; VICTORIA, R. L. (eds.) **Amazonian Deforestation and Climate**. New York: J. M. Wiley and Sons, 1996, p.473-504.

XIN, L.; FEI, H.; GANG, L. Characteristics of chaotic attractors in atmospheric boundary layer turbulence. **Boundary-Layer Meteorology**, v.99, p.335-345, 2001.

ZBILUT, J. P.; WEBBER Jr., C. L. Embeddings and delays as derived from quantification of recurrence plots. **Physics Letters A**, v.171, p.199-203, 1992.

ZBILUT, J. P.; ZALDÍVAR-COMENEGES, J. M.; STROZZI, F. Recurrence quantification based Liapunov exponents for monitoring divergence in experimental data. **Physics Letters A**, v.297, p.173-181, 2002.

ZENG, X.; PIELKE, R. A. What does a low-dimensional weather attractor mean? **Physics Letters A**, v.175, p.299-304, 1993.