

JOSÉ RODRIGO SANTOS SILVA

**AVALIAÇÃO DE AUTOCORRELAÇÕES E COMPLEXIDADE DE
SÉRIES CLIMÁTICAS NO BRASIL**

RECIFE-PE – SET/2014.



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIOMETRIA E ESTATÍSTICA APLICADA

**AVALIAÇÃO DE AUTOCORRELAÇÕES E COMPLEXIDADE DE
SÉRIES TEMPORAIS CLIMÁTICAS NO BRASIL**

Tese apresentada ao Programa de Pós-Graduação em Biometria e Estatística Aplicada como exigência parcial à obtenção do título de Doutor.

Área de Concentração: **Estatística Aplicada e Experimental**

Orientadora: Prof.^a Dr.^a Tatijana Stosic

RECIFE-PE – SET/2014.

Ficha catalográfica

S586a Silva, José Rodrigo Santos
Avaliação de autocorrelações e complexidade de séries temporais climáticas no Brasil / José Rodrigo Santos Silva. – Recife, 2014.
114 f. : il.

Orientadora: Tatijana Stosic.
Tese (Doutorado em Biometria e Estatística Aplicada) – Universidade Federal Rural de Pernambuco, Departamento de Estatística e Informática, Recife, 2014.
Inclui referências e apêndice(s).

1. Clima 2. Fatores climáticos 3. Detrended fluctuation analysis 4. Multiscale sample entropy 5. Kriging I. Stosic, Tatijana, orientadora II. Título

CDD 310

UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIOMETRIA E ESTATÍSTICA APLICADA

**AVALIAÇÃO DE AUTOCORRELAÇÕES E COMPLEXIDADE DE SÉRIES TEM-
PORAIS CLIMÁTICAS NO BRASIL**

José Rodrigo Santos Silva

Tese julgada adequada para obtenção do título de doutor em Biometria e Estatística Aplicada, defendida e aprovada por unanimidade em 19/09/2014 pela Comissão Examinadora.

Orientadora:

Prof.^a Dr.^a Tatijana Stosic
Universidade Federal Rural de Pernambuco

Banca Examinadora:

Prof. Dr. Moacyr Cunha Filho
Universidade Federal Rural de Pernambuco

Prof. Dr. Borko D. Stosic
Universidade Federal Rural de Pernambuco

Prof. Dr. Pedro Hugo de Figueirêdo
Universidade Federal Rural de Pernambuco

Prof. Dr. Milan Lalic
Universidade Federal de Sergipe

Aos meus pais, Lia e José.

AGRADECIMENTOS

Foram muitas histórias ao longo desses anos em que morei em Recife. Muitas coisas legais, outras nem tanto, mas de todas pude tirar aprendizados pra minha vida. Se eu fosse agradecer a cada uma das pessoas que foram importantes nessa caminhada, lembrando a histórias vividas com cada uma delas, teria que escrever um livro, bem maior que esta minha tese. Por isso irei citar apenas o nome de algumas.

Começo agradecendo a minha família, minha base, meu porto seguro. Foi com os meus pais que aprendi as maiores lições da minha vida. Eles me ensinaram a ter caráter, respeitar o próximo e fazer o bem sempre que possível, dentre tantas outras lições. Lutar por aquilo em que se acredita é uma tarefa árdua. Foi difícil me manter de pé em muitos momentos, mas sempre que eu lembrava deles eu recobrava minhas forças e seguia meu caminho. Lia e José, esses são os nomes dos meus heróis. Também agradeço a minha irmã Priscila e minha sobrinha Anne Letícia, que me deu novos motivos pra sorrir.

Tive a sorte de poder trabalhar com grandes professores nesses anos. Tenho muito carinho e gratidão pelos meus orientadores de mestrado e doutorado, os professores Borko Stosic e Tatijana Stosic. Agradeço a ambos pelo carinho, atenção e confiança em meu trabalho. Outros professores com quem convivi também deixaram boas lembranças e trouxeram grandes lições. Muito obrigado aos professores Eufrásio, Moacyr e Thiago. Agradeço também a pessoas que me ajudaram muito no departamento, Marco, Fátima e Zuleide.

Fiz grandes amigos ao longo desses anos. Impossível esquecer de David, Rita, Mariese, Cícero Carlos, Rogério, Alvino, Patrícia, Elias, Gabriel, Anderson, Vinicius, Dennis, Djalma, Josimar, Rivelino, Milton, Silvio, Adriano, Joseilme, Kátia, Lucemberg, Marystella, Renata, Alessandro, Ricardo² (o grandão e o pequenininho), Bárbara, Luiz Henrique, Pedro, Oséas, Luisa e Augusto. Incluo nessa lista todos os professores com quem trabalhei na UAST-UFRPE em Serra Talhada, em especial os professores Cauê e Valéria.

Sempre acabamos nos aproximando mais de algumas pessoas do que outras, e essas merecem um agradecimento especial. Aranildo, grande amigo que sempre está presente. Temos muitas histórias pra contar, e ainda teremos muito mais. Filipe, o louco mais ajuizado que conheci. Leila, sempre disposta a se aventurar. Dâmocles e Gabriela, muito obrigado pela amizade de vocês. Diego, um grande amigo e um grande cabeça dura. Samuel, com quem dividi apartamento por mais de três anos, e que se tornou um grande amigo. Daila, uma grande amiga e uma ouvinte paciente. Lêda e Evelyn, obrigado pela amizade e pelas guloseimas. Thaíze e Emerson, me diverti muito com vocês. Rosilda que me ensinou o valor da palavra “não”, pena que nunca aprendi, nem vou aprender. Ana Clara, minha irmã postiça! Muito obrigado por me deixar fazer parte da história de Sophia. Danila, obrigado pelo carinho e pela paciência. Amanda, que adorava passear no Barro-Macaxeira com aqueles sacos cheios de folhas secas. Patrícia, minha grande amiga, que sempre me faz sorrir. Nadja e suas irmãs, pelo carinho e pelas gordices. Paulo Salgado, o homem dos terremotos. Lázaro que foi meu professor na UFS, um dos responsáveis pela minha ida pra Recife, e que hoje me orgulho em dizer que se tornou um grande amigo. E um agradecimento especial pra minha companheira Hérica, que esteve ao meu lado nos momentos mais difíceis e que hoje torna meus dias mais alegres.

A todos os citados e não citados, muito obrigado por tudo!!!

“Posso não ter um centavo no bolso, mas tenho um sorriso no rosto e isso vale mais que todo dinheiro do mundo”

Seu Madruga

RESUMO

O objetivo deste estudo foi desvendar a dinâmica climática do Brasil, buscando mensurar a regularidade e a autocorrelação de longo alcance em séries climáticas diárias de temperatura do ar (média, máxima, mínima, e amplitude térmica), umidade relativa média do ar e velocidade média diária do vento. Os dados foram obtidos pelo Instituto Nacional de Meteorologia, em 264 estações meteorológicas, no período de janeiro de 1990 a dezembro de 2012. Utilizamos o *Detrended Fluctuation Analysis* para realizar a estimativa do expoente de Hurst, o *Multiscale Sample Entropy* para as estimativas da entropia das séries e o *Kriging* para a interpolação das estimativas realizadas. Observamos que maiores latitudes tendem a atenuar as médias das temperaturas máxima, mínima e média do ar, porém aumentam a variabilidade das mesmas. Esta inversão entre as magnitudes da média e do desvio padrão também é observado na umidade relativa média do ar. As médias dos expoentes de Hurst estimados para todo o Brasil foram 0,81; 0,79; 0,81; 0,77; 0,83 e 0,64; e do *Sample Entropy* estimado, 1,39; 1,78; 1,46; 1,41; 1,56 e 1,66, respectivamente para séries diárias de temperatura média, máxima e mínima do ar, amplitude térmica do ar, umidade relativa média do ar e velocidade média do vento. Os valores do expoentes de Hurst estimados apresentaram uma correlação positiva com a latitude nas variáveis de temperatura do ar estudadas. Tal correlação não foi observada nas demais variáveis. As regularidades das séries climáticas no Brasil foram medianas. Especialmente, as maiores alterações nas estimativas das entropias ocorreram na escala 1 para a 2 de τ , no *Multiscale Sample Entropy*. A partir de $\tau \geq 2$ as mudanças observadas foram mais sutis. Observamos influência da massa de ar Equatorial Continental na entropia das temperaturas do ar média e máxima diárias. O fator climático da altitude atuou com maior frequência sob os resultados observados, principalmente nas variáveis de temperatura. Em alguns casos, a continentalidade e as massas de ar também foram apontados como fatores importantes na caracterização da distribuição espacial das estimativas realizadas.

Palavras-chave: Clima, fatores climáticos, *Detrended Fluctuation Analysis*, *Multiscale Sample Entropy*, *Kriging*.

ABSTRACT

The objective of this study was to uncloak the dynamic of climate of Brazil, seeking to measure the regularity and the long range autocorrelation of daily climate series of temperature of air (average, maximum, minimum, and temperature range), relative humidity of air average and wind speed average. The data were obtained by Instituto Nacional de Meteorologia (INMET), at 264 meteorological stations, in the period from January 1990 to December 2012. We use the Detrended Fluctuation Analysis to realize the estimation of the Hurst exponent, the Multiscale Sample Entropy to estimating the entropy of series and the Kriging to interpolate the estimates made. We observed that higher latitudes tend to attenuate the mean of temperatures of air maximum, minimum and average, but increase the variability of the same. This inversion of the magnitudes of the mean and standard deviation is also observed in the relative humidity of air. The means of the estimated Hurst exponents estimated for Brazil were 0.81, 0.79, 0.81, 0.77, 0.83 and 0.64, and the estimated Sample Entropy, 1.39, 1.78, 1.46, 1.41, 1.56 and 1.66, respectively for average, maximum and minimum temperatures of air, temperature range, relative humidity of air average and wind speed average. The values of the estimated Hurst exponents showed a positive correlation with latitude in the temperature variables studied. Such a correlation was not observed in other variables. This a correlation was not observed in other variables. The regularities of climate series in Brazil were medians. Spatially, the greatest changes occurred in estimates of entropies in the scale 1 to 2 of τ , in the Multiscale Sample Entropy. As from $\tau \geq 2$ the changes observed were more subtle. We observe the influence of the Equatorial Continental air mass in entropy of temperatures daily average and maximum of air. The climatic factor of altitude influenced with more frequently in the observed results, mainly on temperature variables. In some cases, the continentality and the air masses were also identified as important factors in characterizing the spatial distribution of estimates made.

Keyword: Climate, climatic factors, Detrended Fluctuation Analysis, Multiscale Sample Entropy, Kriging.

LISTA DE FIGURAS

Figura 2.1: Zonas Climáticas do Brasil.....	6
Figura 2.2: Cobertura vegetal dos biomas brasileiros.	11
Figura 2.3: Disposição espacial da altimetria do Brasil.	12
Figura 2.4: Caracterização do relevo do Brasil.....	13
Figura 2.5: Distribuição das massas de ar atuantes no Brasil, segundo suas fontes, direcionamento e estações do ano.....	14
Figura 2.6: Fractal Determinístico de Sierpinski Gasket [53]. Uma das maneiras de se obter um triângulo de Sierpinski é através do seguinte algoritmo: Passo 1: Comece com qualquer triângulo em um plano; Passo 2: Encolha o triângulo pela metade. Faça três cópias, e posicione cada triângulo de maneira que encoste nos outros dois em um canto; Passo 3: Repita o passo 2 para cada figura obtida, indefinidamente.....	20
Figura 3.1: Disposição espacial das estações meteorológicas do INMET localizadas no Brasil	28
Figura 3.2: Ilustração do método MSE: transformação da série original usando fator de escala $\tau = 2$ e $\tau = 3$ [35].	31
Figura 3.3: Gráficos de alguns modelos de variogramas.	36
Figura 3.4: Semivariograma experimental e modelo matemático ajustado	37
Figura 4.1: Média (A) e desvio padrão (B) da temperatura do ar média diária do Brasil, no período de 1990 a 2012.	43
Figura 4.2: Estimativas dos expoentes DFA (A) e coeficientes de <i>Sample Entropy</i> (B) das séries diárias de temperatura do ar média do Brasil, no período de 1990 a 2012.	43
Figura 4.3: Coeficiente de entropia (Sample Entropy) das séries de temperatura do ar média diária no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).....	45
Figura 4.4: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (<i>Multiscale Sample Entropy</i>) das séries de temperatura do ar média diária no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).	46

Figura 4.5: Média (A) e desvio padrão (B) da amplitude térmica do ar diária do Brasil, no período de 1990 a 2012.	47
Figura 4.6: Estimativas dos expoentes DFA (A) e coeficientes de <i>Sample Entropy</i> (B) das séries diárias de amplitude térmica do ar do Brasil, no período de 1990 a 2012.	48
Figura 4.7: Coeficiente de entropia (Sample Entropy) das séries de amplitude térmica diária no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30 \text{ dias}$).	49
Figura 4.8: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (<i>Multiscale Sample Entropy</i>) das séries de amplitude térmica do ar diária no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30 \text{ dias}$).	50
Figura 4.9: Média (A) e desvio padrão (B) da temperatura do ar máxima diária do Brasil, no período de 1990 a 2012.	51
Figura 4.10: Estimativas dos expoentes DFA (A) e coeficientes de <i>Sample Entropy</i> (B) das séries diárias de temperatura do ar máxima do Brasil, no período de 1990 a 2012.	52
Figura 4.11: Coeficiente de entropia (Sample Entropy) das séries de temperatura do ar máxima diária no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30 \text{ dias}$).	53
Figura 4.12: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (<i>Multiscale Sample Entropy</i>) das séries de temperatura do ar máxima diária no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30 \text{ dias}$).	54
Figura 4.13: Média (A) e desvio padrão (B) da temperatura do ar mínima diária do Brasil, no período de 1990 a 2012.	56
Figura 4.14: Estimativas dos expoentes DFA (A) e coeficientes de <i>Sample Entropy</i> (B) das séries diárias de temperatura do ar mínima do Brasil, no período de 1990 a 2012.	57
Figura 4.15: Coeficiente de entropia (Sample Entropy) das séries de temperatura do ar mínima diária no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30 \text{ dias}$).	58
Figura 4.16: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (<i>Multiscale Sample Entropy</i>) das séries de temperatura do ar mínima diária no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no	

período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30 \text{ dias}$).	59
Figura 4.17: Média (A) e desvio padrão (B) da umidade relativa média do ar diária do Brasil, no período de 1990 a 2012.	60
Figura 4.18: Estimativas dos expoentes DFA (A) e coeficientes de <i>Sample Entropy</i> (B) das séries diárias de umidade relativa média do ar do Brasil, no período de 1990 a 2012.	61
Figura 4.19: Coeficiente de entropia (Sample Entropy) das séries de umidade relativa do ar média diária no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30 \text{ dias}$).	62
Figura 4.20: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (<i>Multiscale Sample Entropy</i>) das séries de umidade relativa do ar média diária no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30 \text{ dias}$).	63
Figura 4.21: Média (A) e desvio padrão (B) da velocidade média do vento diária do Brasil, no período de 1990 a 2012.	64
Figura 4.22: Estimativas dos expoentes DFA (A) e coeficientes de <i>Sample Entropy</i> (B) das séries diárias de velocidade média do vento do Brasil, no período de 1990 a 2012.	65
Figura 4.23: Coeficiente de entropia (Sample Entropy) das séries de velocidade média do vento diária no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30 \text{ dias}$).	66
Figura 4.24: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (<i>Multiscale Sample Entropy</i>) das séries de velocidade média do vento diária no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30 \text{ dias}$).	67
Figura 7.1: Variogramas séries de médias diária da temperatura do ar média (A), amplitude térmica (B), temperatura do ar máxima (C), temperatura do ar mínima (D), umidade relativa média do ar (E) e velocidade média do vento (F), no Brasil, no período de 1990 a 2012.	80
Figura 7.2: Variogramas séries de desvio padrão diário da temperatura do ar média (A), amplitude térmica (B), temperatura do ar máxima (C), temperatura do ar mínima (D), umidade relativa média do ar (E) e velocidade média do vento (F), no Brasil, no período de 1990 a 2012.	81
Figura 7.3: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de temperatura do ar média diária no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30 \text{ dias}$).	82

Figura 7.4: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de amplitude térmica diária no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).	85
Figura 7.5: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de temperatura do ar máxima diária no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).	88
Figura 7.6: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de temperatura do ar mínima diária no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).	91
Figura 7.7: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de umidade relativa do ar média diária no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).	94
Figura 7.8: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de velocidade média do vento diária no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).	97
Figura 7.9: Variograma dos expoentes DFA das séries diárias de temperatura do ar média (A), amplitude térmica (B), temperatura do ar máxima (C), temperatura do ar mínima (D), umidade relativa média do ar (E) e velocidade média do vento (F).	100

SUMÁRIO

1.	INTRODUÇÃO	1
2.	REVISÃO DE LITERATURA.....	5
2.1	Clima.....	5
2.1.1	Elementos do Clima.....	6
2.1.2	Principais Fatores Climáticos	10
2.2	Entropia.....	14
2.2.1	Uso de entropia em dados climáticos	16
2.3	Expoente de Hurst.....	17
2.3.1	Dinâmica Fractal.....	19
2.3.2	Relação entre dimensão fractal e o expoente de Hurst.....	21
2.3.3	Uso de DFA em dados climáticos.....	22
2.4	Geoestatística	24
3.	MATERIAL E MÉTODOS.....	28
3.1	Dados.....	28
3.2	<i>Sample Entropy (SampEn)</i>	29
3.3	<i>Mustiscale Sample Entropy (MSE)</i>	31
3.4	<i>Detrended Fluctuation Analysis (DFA)</i>	32
3.5	<i>Kriging</i>	34
3.5.1	Semivariância e Variograma.....	34
3.5.2	Modelos de Semivariogramas	35
3.5.3	Inferência Espacial – <i>Kriging</i>	37
4.	RESULTADOS E DISCUSSÃO	41
4.1	Temperatura média do ar.....	42
4.2	Amplitude térmica do ar	46

4.3	Temperatura máxima do ar	51
4.4	Temperatura mínima do ar	55
4.5	Umidade relativa média do ar	59
4.6	Velocidade média do vento	64
5.	CONCLUSÕES	68
6.	REFERÊNCIA	71
7.	APÊNDICE	80

1. INTRODUÇÃO

O estudo do tempo e do clima ocupa uma posição central e importante no amplo campo da ciência ambiental. Os processos atmosféricos influenciam os processos nas outras partes do ambiente, principalmente na biosfera, hidrosfera e litosfera [1]. A partir do momento em que o homem tomou consciência da interdependência das condições climáticas e daquelas resultantes de sua deliberada intervenção no meio natural como necessidade para o desenvolvimento social, ele passou a produzir e registrar o conhecimento sobre os componentes da natureza [2].

Desvendar a dinâmica dos fenômenos naturais foi necessário para que os grupos sociais superassem a condição de meros sujeitos às intempéries naturais e atingissem não somente a compreensão de funcionamento de alguns fenômenos, mas também a condição de utilitários e de manipuladores dos mesmos em diferentes escalas [2]. Devido a sua importância para a vida na terra, o clima é um tema vastamente estudado em diversas áreas, tais como agricultura [3], atividade marítima [4], estudos sobre incêndios florestais [5], entre outras.

O clima do Brasil é diversificado em consequência de fatores variados, como a fisionomia geográfica, a extensão territorial, o relevo e a dinâmica das massas de ar. Este último fator é de suma importância porque atua diretamente tanto na temperatura do ar quanto na pluviosidade, provocando diferenças climáticas regionais [6].

O planejamento de atividades como a agricultura, a produção de energia (hidroelétrica, solar e eólica), a manutenção de recursos hídricos, etc., levam à necessidade de se ter previsões confiáveis das condições de tempo e clima. Desta forma, tem sido constante a preocupação dos cientistas em melhorar as previsões de tempo e clima, o que tem levado à elaboração de técnicas para se chegar a um produto final satisfatório [7].

Apesar do grande avanço para se melhorar a previsão do tempo, algumas regiões apresentam baixa previsibilidade climática, como é o caso da previsão climática para o Sudeste do Brasil. Isso se deve possivelmente pelo fato de que o clima desta região não tem um sinal claro de variabilidade interanual associada ao El Niño/Oscilação Sul, como é o caso de outras regiões da América do Sul como o Nor-

te/Nordeste e Sul [8,9]. Bezerra, Pezzi e Kayano [7] mostraram que no Brasil, regiões onde existe um forte acoplamento entre variabilidade climática e a temperatura da superfície do mar dos oceanos tropicais, como nas regiões Sul e no Nordeste do Brasil, a previsibilidade climática é mais eficiente que em outras regiões, como o Sudeste do Brasil. De fato, as previsões climáticas por conjunto, realizadas atualmente com modelos dinâmicos para a região Sudeste do Brasil, apresentam uma baixa eficiência de previsibilidade climática. Portanto, as diversas regiões da América do Sul apresentam-se heterogêneas em termos de previsibilidade climática, mesmo quando se utiliza a previsão por conjuntos.

As modificações no clima podem ocorrer devido a variabilidade natural ou antropogênica interna ou externa ao sistema climático. A variabilidade natural é expressa pela radiação solar ou atividades vulcânicas, enquanto que as ações antropogênicas são principalmente devido a emissão de gases do efeito estufa. Uma das principais evidências do aumento do efeito estufa é a forte correlação entre o CO_2 na atmosfera e a temperatura média do ar no globo [10].

Estudos divulgados em 2001, pelo *Intergovernmental Panel on Climate Change* (IPCC) [11], mostram que a temperatura média do mar a nível global tem aumentado desde 1861. No século vinte o aumento ficou entre $0,6 \pm 0,2^\circ C$. Entre 1950 e 1993 a temperatura mínima noturna na terra aumentou cerca de $0,2^\circ C$ por década. Este é duas vezes maior que a proporção do aumento da temperatura do dia. O aumento da temperatura da superfície do mar sobre o período é cerca de metade da temperatura média do ar na terra. De acordo com cenários previstos, a temperatura média do globo poderá aumentar de $1,4$ a $5,8^\circ C$ em 2100 com relação a 1990 e globalmente o nível do mar poderá aumentar de $0,09$ a $0,88 m$ no mesmo período.

Ainda segundo o relatório do IPCC [11], tal aquecimento não atingirá o planeta de forma homogênea, pois algumas regiões sofrerão maior impacto do que outras. Em particular, as regiões polares e as tropicais serão afetadas mais fortemente. Nessas últimas, a temperatura do ar pode aumentar em torno de 2 a $6^\circ C$ até 2100. Especificamente na Amazônia, a temperatura do ar poderá sofrer um aumento médio de $1,8$ a $7,5^\circ C$ até 2080, o que traria graves consequências para os seus ecossistemas, com perda de habitat e extinção de espécies. Para Pinto et al. [12], as magnitudes de tais previsões são ainda incertas, pois pouco se sabe sobre os processos de trocas de calor, de carbono e de radiação entre os diversos sistemas da Terra.

Elementos de física, estatística e biologia são usados para entender a variabilidade climática. O clima apresenta variabilidade no espaço e no tempo. A escala temporal pode variar de horas até milênios. O estudo do comportamento climático na escala de décadas, ou tempos maiores, permite analisar a influência do comportamento climático sobre o sistema global [2,10]. O impacto da variabilidade climática não é uniforme. Ao mesmo tempo em que em algumas partes do planeta há aquecimento, em outras pode estar ocorrendo esfriamento. Assim, os resultados das mudanças climáticas podem acarretar, em determinado local, na ocorrência de temperaturas do ar mais baixas em algumas épocas do ano, e mesmo diante deste fenômeno a média de temperatura do ar anual pode ser mais alta [13].

O objetivo deste estudo foi fornecer informações que possam aprimorar modelos de previsão climática. Avaliamos a complexidade e a persistência no tempo das variáveis de temperatura diária do ar (máxima, mínima, média e amplitude térmica), umidade relativa média diária do ar e velocidade média diária do vento. Tais estimativas foram realizadas para 264 estações meteorológicas, e posteriormente interpoladas, ampliando a estimativa para todo o território brasileiro. Desta forma, avaliamos o comportamento destas estatísticas no espaço. A medida de complexidade utilizada (*Multiscale Sample Entropy*) mostrou a variabilidade climática nas regiões em diferentes escalas de dias, já a correlação de longo alcance (persistência), medida através do expoente de Hurst, caracterizou a manutenção dos comportamentos observados ao longo do tempo.

Esta tese está organizada da seguinte maneira: No Capítulo 2 apresentamos fundamentos teóricos que serviram como base para o desenvolvimento do trabalho. Abordamos conceitos sobre o clima, e seus principais elementos e fatores. Além destas definições, mostramos os conceitos básicos sobre os quais foram construídas as metodologias utilizadas neste trabalho (entropia e fractais). Junto com essas definições, fez-se uma revisão de literatura com ênfase em aplicações destes métodos em dados climatológicos. No Capítulo 3 descrevemos os dados utilizados neste trabalho e as metodologias utilizadas para a realização das análises. Os resultados do trabalho são apresentados no Capítulo 4, onde discutimos os resultados obtidos tomando como base o referencial apresentado no Capítulo 2. As considerações finais de toda discussão apresentada no Capítulo 4, é apresentada no Capítulo 5. Por fim,

o Apêndice apresenta os variogramas estimados para a realização das interpolações espaciais observados no Capítulo 4.

2. REVISÃO DE LITERATURA

2.1 Clima

O clima se refere às características da atmosfera inseridas das observações contínuas durante certo período. Ele abrange maior número de dados e eventos possíveis das condições de tempo para uma determinada localidade ou região. Inclui considerações sobre os desvios em relação às médias, variabilidade climática, condições extremas e frequências de eventos que ocorrem em determinada condição do tempo [13].

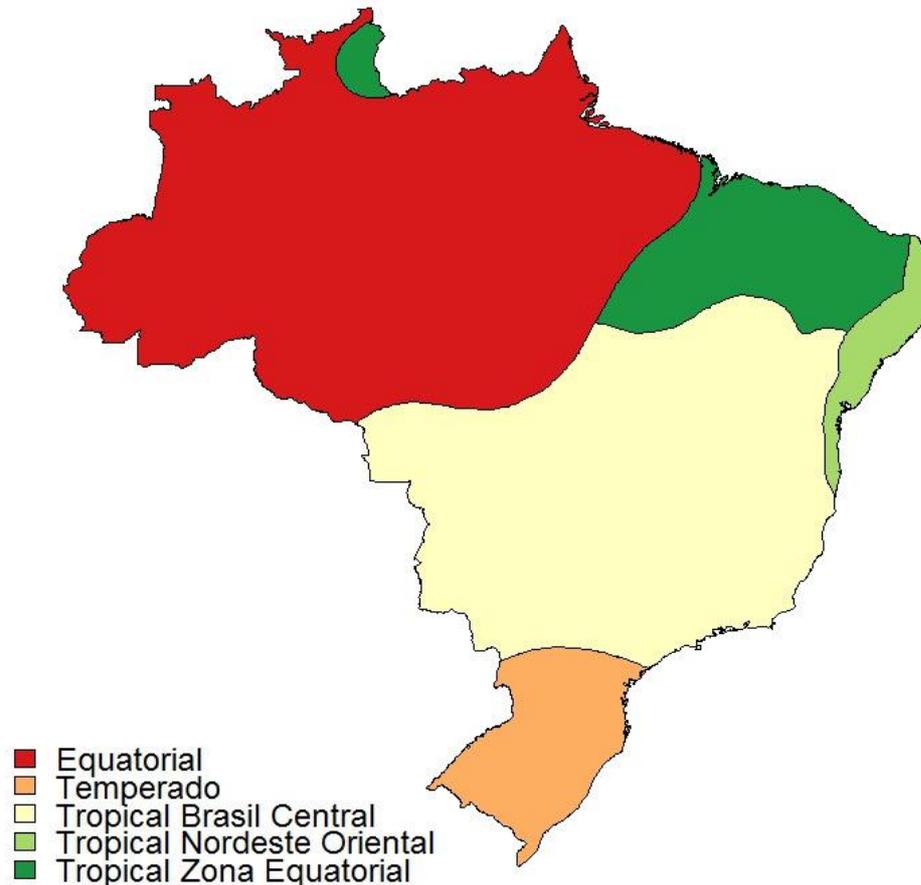
O clima pode mudar se ocorrerem variações em fenômenos climáticos em relação às médias históricas. Essas variações podem ser causadas pela ação humana, pelo sistema Terra-Atmosfera, ou por forças externas, como variações na atividade solar. No Brasil, o clima é bastante diversificado em consequência da fisionomia geográfica, da extensão territorial, do relevo e das dinâmicas das massas de ar [14]. De uma forma geral, “variabilidade climática” é definida como as variações de clima em função dos condicionantes naturais do planeta e suas interações, resultando assim a denominação de variabilidade natural do clima [15,16].

Segundo Back [17] mudança climática é um termo completamente geral que engloba todas as formas de inconstâncias climáticas de natureza estatística ou de causas físicas. Flutuação climática é qualquer forma de mudança sistemática regular ou irregular, exceto tendências e mudanças abruptas. Oscilação climática é a flutuação na qual a variável tende a mover-se gradualmente e de forma suave entre sucessivos máximos e mínimos. A tendência climática é uma mudança no clima caracterizada por um suave acréscimo ou decréscimo nos valores médios no período de registro. A mudança climática abrupta é uma mudança inesperada e permanente, durante o período de registro, de um valor médio para outro.

O clima do Brasil é diversificado em consequência de fatores variados, como a fisionomia geográfica, a extensão territorial, o relevo e a dinâmica das massas de ar. A maior parte do território brasileiro está situado na faixa intertropical (entre os Trópicos de Câncer e de Capricórnio). Essa “tropicalidade” resulta em uma configu-

ração climática que apresenta considerável luminosidade do céu (insolação) e elevadas temperaturas do ar, aliadas à pluviosidade (clima quente e úmido) [2].

Figura 2.1: Zonas Climáticas do Brasil.



Fonte: IBGE, 2014 [18].

2.1.1 Elementos do Clima

Elementos do clima são grandezas meteorológicas (possíveis de serem medidas) que variam no tempo e no espaço. Suas características e propriedades peculiares são temperatura e umidade relativa do ar, chuva, vento, nebulosidade, pressão atmosférica, radiação solar etc. [2]. Neste trabalho foi estudado o comportamento de três elementos do clima em escalas diárias: temperatura do ar (máxima, míni-

ma, média e amplitude térmica), umidade relativa do ar (média diária), e vento (velocidade média diária).

A temperatura do ar representa a medida do calor sensível armazenada no ar, sendo comumente dada em graus Celsius ou Fahrenheit, e medida por termômetros. A variável temperatura do ar média diária habitualmente sofre uma compensação de acordo com o horário em que foram realizadas as medições. A temperatura do ar compensada média diária, obtida nas estações meteorológicas do Instituto Nacional de Meteorologia (INMET) é dada por

$$T = \frac{T_{9h} + 2 \times T_{21h} + T_{máx} + T_{mín}}{5}. \quad (2.1.1)$$

onde T_{9h} é a temperatura do ar registrada às 9 horas; T_{21h} é a temperatura do ar registrada às 21 horas; $T_{máx}$ é a maior temperatura do ar registrada ao longo do dia; e $T_{mín}$ é a menor temperatura do ar registrada ao longo do dia.

Em situações normais, conforme Varejão-Silva [19], o valor máximo ocorre cerca de duas horas depois da culminação do Sol e o mínimo acontece pouco antes do nascimento do Sol. A presença de fenômenos capazes de perturbar o estado prevalecente da atmosfera (como uma invasão de ar frio, por exemplo), pode alterar a expectativa quanto aos horários prováveis de ocorrência das temperaturas do ar extremas.

A diferença entre temperaturas do ar máximas e mínimas ($T_{máx} - T_{mín}$) é definida como amplitude térmica [2]. As temperaturas do ar máxima e mínima correspondem, respectivamente, aos maiores e menores valores registrado em qualquer período considerado (dia, semana, mês, ano). Segundo Varejão-Silva [19], a temperatura do ar média do ar à superfície (em termos mensais, ou anuais), aumenta dos polos para o equador, enquanto sua amplitude cresce no sentido contrário. O fato das mais elevadas temperaturas do ar médias se situarem nas proximidades do equador decorre da maior incidência de energia solar na faixa tropical.

A presença de vapor de água na atmosfera é tratada como umidade. Os termos pressão de vapor, umidade absoluta, umidade específica, razão de mistura e umidade relativa do ar são variações na forma de abordar a presença de vapor. A pressão de vapor refere-se ao peso do vapor dado pela pressão que ele exerce sobre uma superfície no nível médio do mar. A unidade de medida comumente usada é

o milibar (*mb*). A umidade relativa do ar (variável utilizada em nosso estudo) expressa uma relação de proporção entre o vapor existente no ar e o ponto de saturação do mesmo. Em outras palavras, ela mostra em termos percentuais o quanto o vapor está presente no ar em relação a quantidade máxima de vapor que nele poderia haver. A umidade relativa do ar é dada por

$$UR = \frac{v}{p_{sv}} \times 100, \quad (2.1.2)$$

onde v (usualmente em gramas) é o vapor existente e p_{sv} é a pressão saturada do vapor (em gramas) para dada temperatura do ar [2]. A Lei de Clausius-Clapeyron [20,21] descreve esta relação.

Pela expressão vê-se que a umidade relativa do ar e o ponto de saturação do vapor são inversamente proporcionais, conseqüentemente ela também será inversamente proporcional a temperatura do ar. Assim, podemos concluir que o aumento (ou diminuição) da temperatura do ar irá resultar na diminuição (ou aumento) da umidade relativa do ar. Isso faz com que uma variação observada na umidade relativa do ar não necessariamente signifique ter havido uma mudança na concentração de vapor d'água do ar. A alteração na umidade relativa do ar pode advir exclusivamente de alteração na temperatura ambiente. Como consequência desse efeito deve-se esperar que a umidade relativa do ar diminua a partir do nascimento do Sol, atingindo o valor mínimo nas horas mais quentes do dia, voltando a aumentar em seguida, apenas por efeito térmico. Além desse fator, a localização relativa das fontes e sumidouros de vapor d'água, o suprimento de energia solar, a circulação das massas de ar, etc., podem influir na formação da umidade do ar, tanto no tempo quanto no espaço [19].

De acordo com Santos [14], o vento é o movimento do ar em relação à superfície terrestre. Este movimento pode acontecer tanto no sentido horizontal como no sentido vertical. O vento se desloca das áreas de alta pressão para as áreas de baixa pressão, mantendo, em geral, as características da atmosfera de onde vieram.

A velocidade e a direção dos ventos são medidas pelo anemômetro, sendo que a primeira é comumente dada em nós, *km/h* ou *m / s*. A rugosidade do solo é um fator redutor da velocidade dos ventos em superfície, uma vez que desempenha um efeito de fricção sobre os ventos. Assim, os oceanos favorecem a formação de ventos velozes, enquanto os continentes, devido à heterogeneidade da cobertura de

suas superfícies (vegetação, construções, relevo montanhoso, etc.) e às suas características geomorfológicas, tendem a reduzi-la [2]. Podemos classificar a velocidade dos ventos conforme a escala de Beaufort (Tabela 2.1).

Tabela 2.1: Classificação da velocidade dos ventos de acordo com Beaufort [2]

Grau	<i>m / s</i>	Classificação	Características da Paisagem
0	0,0 – 0,3	Calmo	A fumaça sobe verticalmente e as bandeiras pendem tranquilas.
1	0,3 – 1,6	Leve	A fumaça desvia-se um pouco e indica a direção do vento.
2	1,6 – 3,4	Brisa leve	Sente-se o vento nas faces, as folhas das árvores alvoroçam-se.
3	3,4 – 5,5	Brisa suave	As folhas das árvores movem-se constantemente, as bandeiras desfraldam-se.
4	5,5 – 8,0	Vento moderado	Galhos finos de árvores curvam-se e começa a levantar poeira e papel do solo.
5	8,0 – 10,8	Vento fresco	Pequenas árvores em crescimento começam a se curvar e bandeiras flamulam estendidas.
6	10,8 – 13,9	Vento forte	Galhos grandes curvam-se, arames silvam e formam-se crostas de espuma sobre as ondas.
7	13,9 – 17,2	Vento rápido	As árvores movem-se por inteiro, é difícil caminhar contra o vento.
8	17,2 – 20,8	Ventania	Quebram-se ramos de árvores e é muito difícil caminhar contra o vento.
9	20,8 – 24,5	Ventania forte	Estragos leves em casas, telhas são arrancadas e quebram-se galhos de árvores.
10	24,5 – 28,5	Ventania desenfreada	Árvores são arrancadas e janelas são quebradas.
11	28,5 – 32,7	Tempestade	Estragos generalizados em construções
12	≥ 32,7	Furacão ou ciclone	Destruição geral

Uma melhor compreensão da variabilidade temporal e espacial da velocidade e direção do vento é fundamental para a modelagem de diversos fenômenos como a erosão do solo [20], a formação de duna [21], a poluição do ar [22], pólen e geração de dispersão de sementes [23,24], a evapotranspiração [25], e de energia [26].

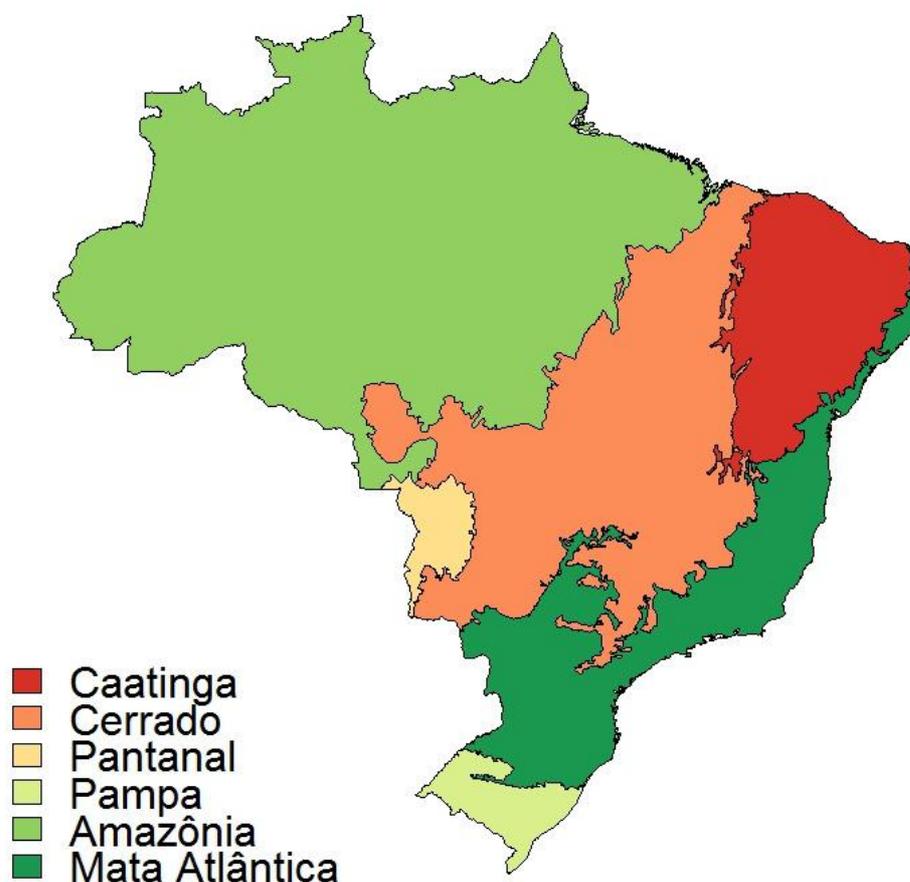
2.1.2 Principais Fatores Climáticos

Os fatores climáticos são definidos pelos atributos físicos que representam as propriedades da atmosfera geográfica de um dado local [2,27]. Eles são condicionantes dos elementos climáticos, e podem ser classificados como permanentes (destacando-se latitude, altitude, relevo, maritimidade/continentalidade, distribuição de oceanos e continentes e movimentos da Terra) e variáveis (as correntes oceânicas, os centros de alta e baixa pressões semipermanentes, as grandes massas de ar, e as variações da composição atmosférica), no espaço e no tempo [28].

A latitude é a coordenada geográfica ou geodésica definida na esfera, no elipsoide de referência ou na superfície terrestre, que é o ângulo entre o plano do equador e a normal à superfície de referência. Conforme descrito por Pereira et al. [28], os efeitos deste fator permanente estão ligados às relações Terra-Sol, que envolvem o movimento aparente do Sol ao longo do ano. Como consequência do movimento de translação da Terra, e também da inclinação do eixo terrestre em relação ao Plano da Eclíptica (plano da órbita da Terra ao redor do Sol), há variação espacial e temporal do ângulo de incidência dos raios solares na superfície e do fotoperíodo. Em função disso os valores diários de irradiação solar global variam de acordo com a latitude e com o dia do ano, sendo também afetados pelos processos de atenuação na atmosfera. Isto torna a latitude um grande fator condicionador do balanço de energia radiante, com tendência de diminuição da temperatura média quando se vai das regiões equatoriais para as polares.

A estreita relação entre clima e vegetação é evidenciada pela coincidência entre zonas climáticas e biomas (Figura 2.1 e Figura 2.2). Bioma é um conjunto de diferentes ecossistemas, que possuem certo nível de homogeneidade. São as comunidades biológicas, ou seja, as populações de organismos da fauna e da flora interagindo entre si e interagindo também com o ambiente físico chamado biótopo. A vegetação também é um fator climático, ela impede a incidência direta dos raios solares na superfície, amenizando o aquecimento. Além disso, a vegetação também tem impacto no ciclo hidrológico devido à emissão de vapor de água no ar, influenciando também a umidade relativa do ar. Pode-se observar a disposição espacial da cobertura vegetal dos diferentes biomas presentes no Brasil na Figura 2.2.

Figura 2.2: Cobertura vegetal dos biomas brasileiros.



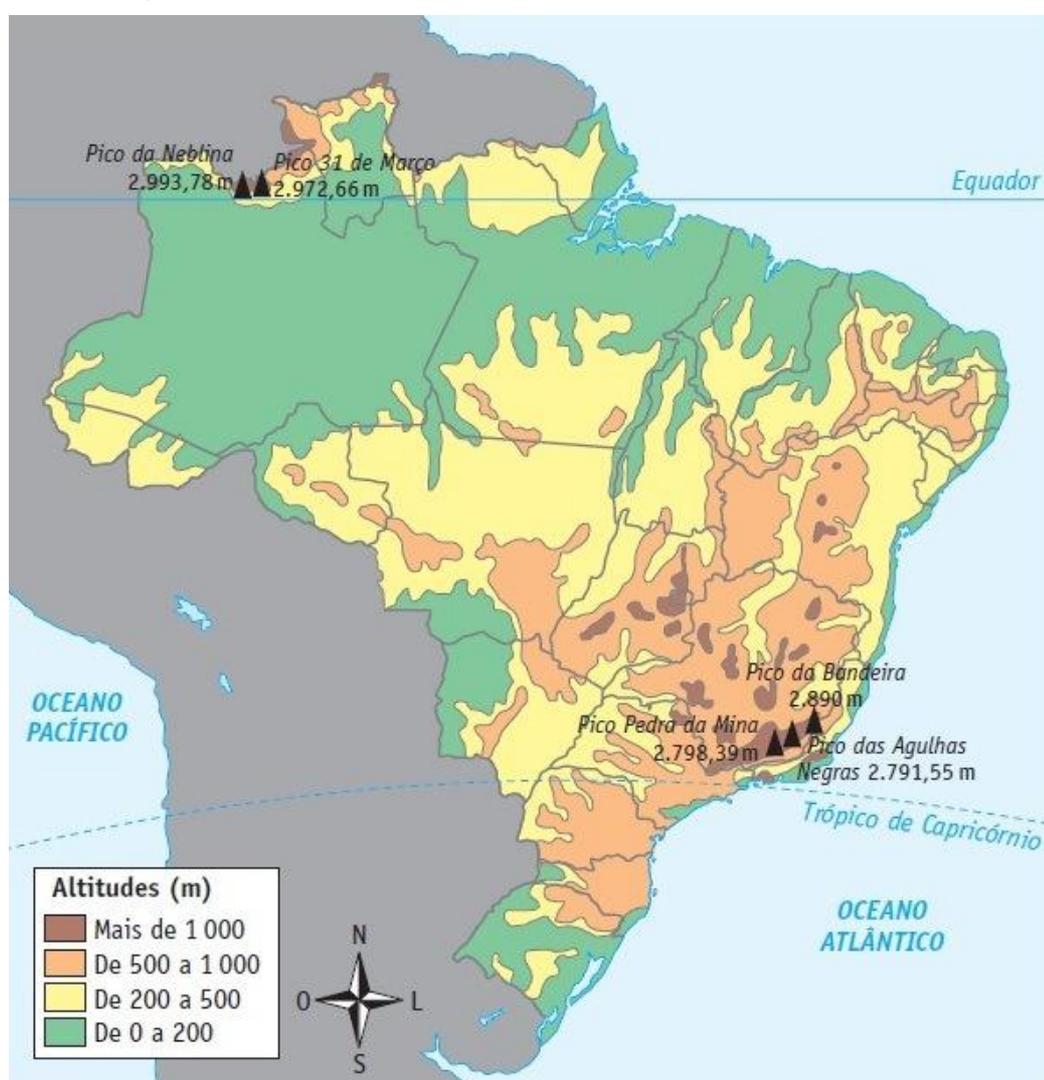
Fonte: IBGE, 2014 [18].

Continentalidade e maritimidade são dois conceitos associados, onde o primeiro é definido como sendo a distância de certo lugar em relação aos mares e oceanos, e o segundo, a proximidade de certo local em relação aos mares e oceanos. Conforme Varejão-Silva [19] e Pereira et al. [28] descrevem, a água possui um maior calor específico da em relação aos solos. Em consequência, mares e oceanos agem como moderadores térmicos, ou seja, sua flutuação térmica é menor ao longo do dia e do ano. Essa característica é transmitida à atmosfera em localidades litorâneas, onde a amplitude térmica do ar é menor do que a das localidades situadas no interior do continente.

Altitude é definida como sendo a altura em relação ao nível do mar. As baixas altitudes são predominantes no Brasil (Figura 2.3), sendo consequência da antigui-

dade da formação do seu relevo e da ausência de dobramentos modernos [29]. O aumento da altitude implica uma diminuição da temperatura do ar. Isso ocorre porque a concentração de gases e de umidade relativa do ar diminui com a altitude, o que ocasiona uma menor retenção de calor. Segundo Mendonça e Danni-Oliveira [2], considerando dois lugares de mesma latitude, porém com altitudes diferentes, aquele que estiver mais elevado terá sua temperatura do ar diminuída na razão $0,6^{\circ}\text{C}$ para cada 100 m de diferença do segundo.

Figura 2.3: Disposição espacial da altimetria do Brasil.

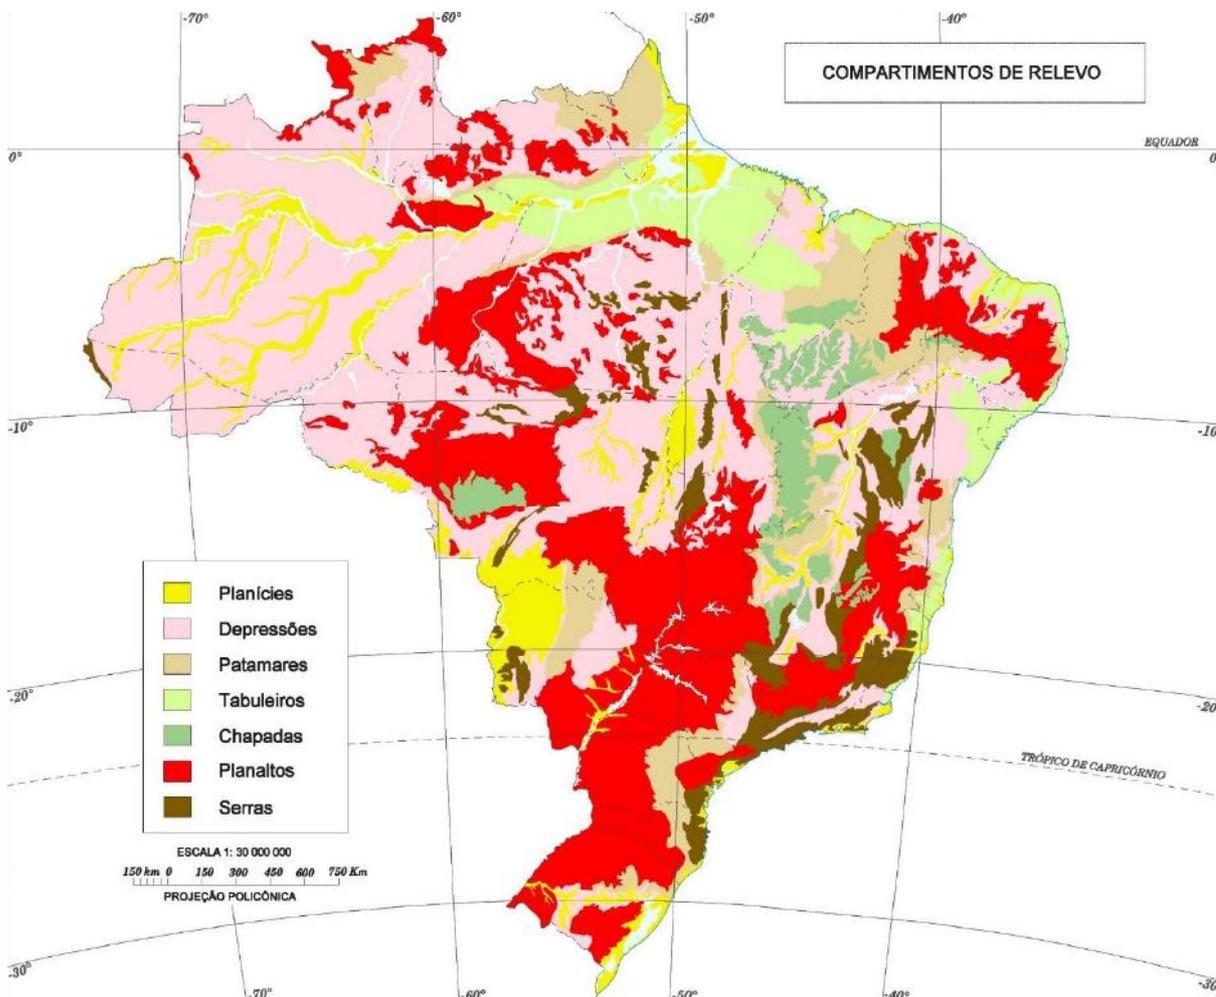


Fonte: IBGE, 2002 [29].

Segundo Pereira et al. [28], a associação da altitude de um local na superfície terrestre com o relevo pode condicionar variações no regime de chuvas e de ventos do local. Já a interferência de montanhas e depressões influencia na circulação das

massas de ar. A topografia pode facilitar ou dificultar esta circulação, influenciando na temperatura e umidade do ar.

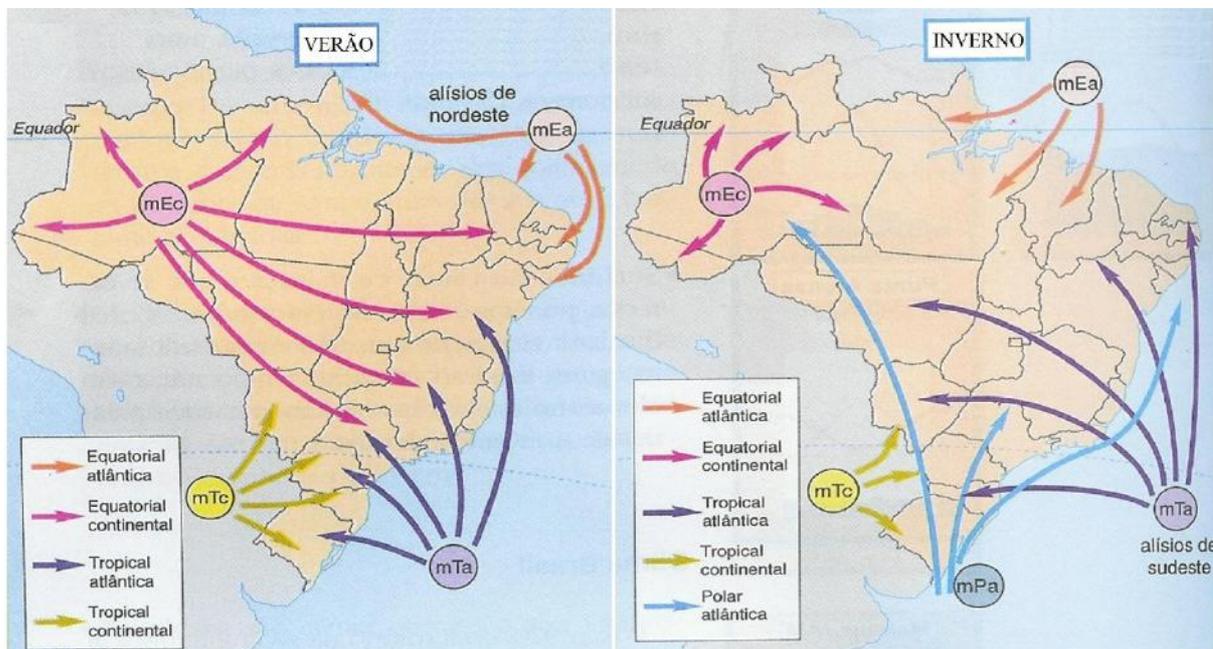
Figura 2.4: Caracterização do relevo do Brasil.



Fonte: IBGE, 2014 [18].

Massas de ar são grandes blocos de ar que se deslocam pela superfície terrestre. Podem ser polares, tropicais ou equatoriais, apresentando características particulares da região em que se originaram, como temperatura, pressão e umidade. Observa-se na Figura 2.5 as fontes e direcionamentos das massas de ar atuantes no Brasil, discriminadas de acordo com as estações de inverno e verão. Pereira et al. [28] descrevem que quando ocorre o encontro de duas massas de ar, elas não se misturam imediatamente. A massa mais quente (menos densa) se sobrepõe à massa mais fria (mais densa), formando uma zona de transição entre elas, onde ocorrem variações bruscas nos campos de temperatura, vento e pressão. Essa zona de transição é denominada frente.

Figura 2.5: Distribuição das massas de ar atuantes no Brasil, segundo suas fontes, direcionamento e estações do ano.



Fonte: IBGE, 2002 [29].

Correntes Marítimas são grandes massas de água com as mesmas características (temperatura, salinidade, cor, direção, densidade) e circulam pelo oceano. Exercem grande influência nas massas de ar que se formam acima delas, pois podem acumular uma grande quantidade de calor. O contorno dos continentes impõe direção à movimentação das correntes oceânicas. As correntes que circulam no sentido dos Polos para o Equador são frias, enquanto que aquelas que navegam no sentido contrário, são aquecidas. Essa movimentação ajuda a redistribuir a energia solar captada pelos oceanos [28].

2.2 Entropia

Em física, entropia é uma medida da quantidade de desordem que há em um sistema. Já em estatística, é uma medida da quantidade de incerteza (ou regularidade) que há em certa quantidade de dados, em outras palavras, é a medida da quantidade de informação regular presente nesses dados. Em séries temporais, a entropia nos dará o grau de complexidade de uma série. Desta forma, se considerarmos uma série histórica de temperatura do ar média, uma baixa entropia significa uma baixa complexidade ou variabilidade da série, indicando que esta é uma série da

qual tende a ser mais fácil realizar previsões, uma vez que a variabilidade dos dados é baixa. Já quando houver uma alta entropia, entenderemos que esta é uma série difícil de ser modelada e conseqüentemente de se realizar previsões. Uma entropia nula equivale a uma série constante, totalmente regular, enquanto que uma entropia máxima (dentro da escala da qual está se realizando a medida) representa uma série totalmente irregular.

Pincus e Viscarelo [30] sugerem uma técnica denominada *Approximate Entropy* (*ApEn*) com o objetivo de mensurar e classificar a entropia de sistemas complexos. Segundo os autores a técnica proposta é capaz de realizar essas mensurações em séries com pelo menos 1000 observações, em diversas configurações (por exemplo, séries caóticas e processos determinísticos). Além desta, outras medidas também foram baseadas no conceito de entropia, buscando quantificar a complexidade estrutural em um processo temporal. Pode-se citar como medidas de entropia, além do *ApEn*, a *Shannon Entropy* [31] e *Kolmogorov Entropy* [32].

Para Richman e Moorman [33], os métodos até então apresentados para estimar a entropia de um sistema, representado por uma série de tempo, não eram adequados para a análise de séries curtas e ruidosas, comumente encontradas em estudos biológicos cardiovasculares, por exemplo. Eles então propuseram um novo método para o cálculo da entropia, denominado de *Sample Entropy* (*SampEn*). Este novo método é uma modificação do método *ApEn*, proposto por Pincus e Viscarelo [30]. A comparação dos dois métodos indicou que o *SampEn* apresenta uma melhor precisão estatística do que o *ApEn*.

Diante do interesse na quantificação da complexidade das séries temporais fisiológicas, tais como frequência cardíaca, Costa et al. [34] observaram que os algoritmos tradicionais indicavam maior complexidade de certos processos patológicos, associando o fenômeno a estados aleatórios, ao invés de convergir para dinâmicas que indicassem uma melhora do paciente. Desta forma, eles propuseram um método que pudesse captar a complexidade da patologia ao longo do tempo. O método foi denominado *Multiscale Sample Entropy*, e é uma generalização do método proposto por Richman e Moorman [33].

Costa et al. [35] usaram o *Multiscale Sample Entropy* para observar as flutuações do batimento cardíaco humano em diferentes escalas temporais, e observaram que método indica uma perda de complexidade com o envelhecimento, com uma

arritmia cardíaca (fibrilação atrial) irregular. Os resultados condisseram com a teoria geral de que há uma perda da complexidade com o envelhecimento da doença.

2.2.1 Uso de entropia em dados climáticos

Na literatura, as maiores aplicações do *Sample Entropy* estão em estudos clínicos e médicos, em estudos de observação de processos fisiológicos [36,37,38]. Na hidrologia este método também é bastante explorado, em estudos da variabilidade temporal da vazão fluvial de rios [39,40]. Na climatologia, além do *SampEn*, demais medidas (*ApEn*, *Shannon Entropy* e *Kolmogorov Entropy*) também vêm sendo utilizadas para a realização de estimativas da entropia.

Huang et al. [39] estudou a complexidade temporal e a tendência da vazão fluvial de alguns rios da China. Este estudo também foi estendido à série de precipitação na região de curso dos rios. Observou-se que o aumento da entropia na série de precipitação é acompanhado pelo aumento da entropia da vazão fluvial do rio em estudo.

Shuangcheng et al. [41] propuseram o uso do *SampEn* para medir a complexidade de séries de temperatura do ar diária. Estas estimativas foram calculadas para 50 estações meteorológicas das montanhas do sudoeste da China, na província de Yunnan. A partir dos resultados, as estações foram agrupadas em regiões climáticas de acordo a entropia estimada. Este padrão espacial determinado através do *SampEn* refletiu o grau de variação de influência das massas de ar. Altos valores do *SampEn* ocorreram em regiões de interação de diversas massas de ar. Na região sudoeste, a influência das monções criou um ambiente climático homogêneo, os valores de *SampEn* nessa região são baixos e há pequenas variações espaciais da estatística. Os resultados sugeriram que *SampEn* é um bom método não-linear para analisar e prever a complexidade de séries temporais climáticas.

Estudo semelhante foi realizado por Kossobokov et al. [42] na Europa, onde foi utilizada a medida *Shannon Entropy* para estudar a estabilidade e variabilidade de séries de temperatura do ar máxima e mínima, no tempo e no espaço. Seus dados foram provenientes do registro de 24 estações meteorológicas localizadas no continente. Não foi observado o efeito da maritimidade nas entropias estimadas. Ob-

servou-se que os valores entrópicos aumentaram na direção Oeste-Leste, ou seja, a estatística *Shannon Entropy* aumentou juntamente com a longitude, que não é considerado um fator climático.

Zhao *et al.* [43] realizaram na China um estudo para avaliar a dinâmica do clima no país, onde utilizaram séries históricas de temperatura do ar média, máxima e mínima, captadas por 17 estações meteorológicas distribuídas ao longo do planalto do Tibete. Eles utilizaram o *ApEn* como medida de entropia, e encontraram diferentes valores entrópicos na região, porém estas diferenças não mostraram correlação com os fatores climáticos mais influentes na região, a altitude e a vegetação.

No Brasil, Silva *et al.* [44] realizaram uma caracterização climática dos diferentes biomas presentes no país utilizando o *SampEn*. Eles utilizaram séries históricas de temperatura do ar média, e observaram que o Brasil não apresenta uma dinâmica climática de grande complexidade, sendo o Cerrado o bioma que apresentou as maiores regularidades.

A análise das propriedades de velocidade e direção do vento são úteis para a compreensão do mecanismo de dispersão de odores e gases. Para entender melhor essa dinâmica, Li *et al.* [45] analisaram a entropia de séries históricas de direção e velocidade do vento na China, utilizando o *Multiscale Sample Entropy*. Os resultados indicaram que a entropia da velocidade do vento em ambientes próximos a superfícies externas (como o telhado de uma fábrica, por exemplo) é maior que zero, e esta entropia aumenta à medida que nos distanciamos da superfície. Em geral, altas médias de velocidade do vento são associadas a valores altos de entropia. Já quando comparamos a distribuição de probabilidade da série de velocidade do vento, temos que quando maior a curtose da distribuição, menor será a entropia da série.

2.3 Expoente de Hurst

Os estudos do hidrólogo Harold Edwin Hurst relativos ao nível do rio Nilo iniciaram-se quando este foi confrontado com o problema de regularizar sua vazão [46]. Seu trabalho foi construir uma represa de água no Nilo, onde se deparou com problemas relacionados com a armazenagem de água, mais precisamente o controle da vazão, pois um reservatório ideal nunca deve esvaziar e nem transbordar. Na

construção de um modelo de plano de controle da vazão, uma parte do sistema deve ser assumida como incontrolável, neste caso, a influência (fluxo) das águas das chuvas, de comportamento aleatório (randômico). Ao testar esta suposição, inventou um novo método estatístico, descrito por ele em detalhes em [47].

Hurst examinou 800 anos de registros e observações do nível das enchentes anuais e notou a existência de uma tendência de um ano de grande inundação ser seguido por outro ano de grande inundação e um ano de pouca inundação ser seguido por outro ano de pouca inundação. Isto aparentava um comportamento não-aleatório de anos bons e anos ruins. Este comportamento foi denominado persistente. Caso o ano bom seja seguido de ano ruim, tal comportamento denomina-se anti-persistente [48].

Mais tarde, nas décadas de 60 e 70, estes estudos realizados por Hurst, foram retomados por Mandelbrot. Para referir-se ao comportamento das inundações do rio Nilo, Mandelbrot e Wallis [49] usaram o termo “Efeito José” para qualquer fenômeno que apresenta persistência como este, referindo-se a interpretação dos sonhos do faraó do Egito de que sete anos de fartura (vacas gordas) são seguidos dos sete anos de fome (vacas magras), da estória Bíblica de José, no Egito.

Conforme Feder [50], o problema estudado por Hurst consistia em determinar o volume de um reservatório, conhecendo-se o fluxo de entrada $\xi(t)$, considerando que seu fluxo de saída seja igual a média de $\xi(t)$. Considerando um intervalo de tempo τ , a média do fluxo será,

$$\langle \xi \rangle_\tau = \frac{1}{\tau} \sum_{t=1}^{\tau} \xi(t). \quad (2.3.1)$$

Seja $X(t)$ a diferença acumulada entre o fluxo de entrada e sua média

$$X(t, \tau) = \sum_{u=1}^t \{\xi(u) - \langle \xi \rangle_\tau\}; \quad (1 \leq t \leq \tau). \quad (2.3.2)$$

A diferença entre o valor máximo e o mínimo das descargas acumuladas (X) é a medida de range (R). Então, R é a capacidade de armazenamento necessária para manter a descarga média no período. Para um reservatório que nunca transborda e nem esvazia, R é a diferença entre o máximo e o mínimo da quantidade de água contida no reservatório. Portanto, R pode ser representado pela expressão [48]:

$$R(\tau) = \max_{1 < t < \tau} X(t, \tau) - \min_{1 < t < \tau} X(t, \tau); (1 \leq t \leq T), \quad (2.3.3)$$

onde $R(\tau)$ é a variação entre a quantidade de água máxima e mínima; $\max_{1 < t < \tau} X(t, \tau)$ é o nível máximo; $\min_{1 < t < \tau} X(t, \tau)$ é o nível mínimo; τ é o período de tempo em anos e t é determinado ano do período. Obviamente $R(\tau)$ depende do fluxo $\xi(t)$, que por sua vez depende do período τ .

Hurst investigou muitos fenômenos naturais, tais como descargas de rio, sedimentos de lama, anéis de árvores, etc., e percebeu que R dependia do período τ como uma lei de potência,

$$\frac{R}{S} = \left(\frac{\tau}{2}\right)^H \quad (2.3.4)$$

no qual H é o expoente de Hurst e S é o desvio padrão do fluxo de entrada de águas nestes reservatórios, definido por

$$S = \left(\frac{1}{\tau} \sum_{t=1}^{\tau} \{\xi(t) - \langle \xi \rangle_{\tau}\}^2\right)^{1/2} \quad (2.3.5)$$

introduzido apenas para que a variável R/S seja um número adimensional, tornando mais fácil a comparação com outros fenômenos [47].

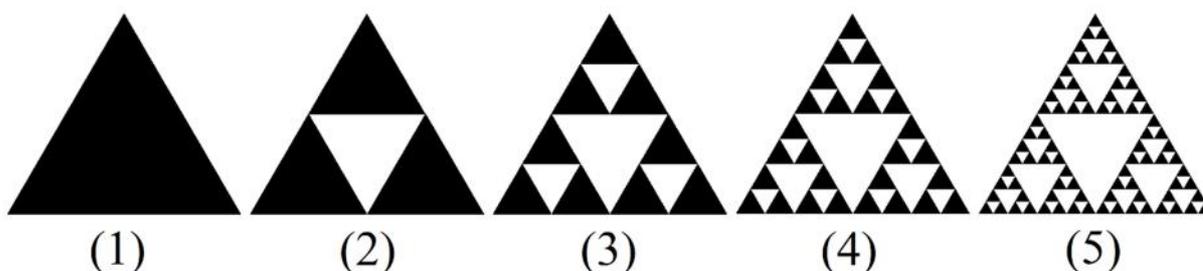
Para os períodos de cheia do Rio Nilo, Hurst encontrou $H = 0,72$. Além de fazer este estudo para o Rio Nilo, Hurst estudou outros fenômenos naturais dependentes do tempo e encontrou o mesmo valor para o parâmetro H . Caso o valor deste expoente coincidisse com 0,5 (representando séries independentes) estaria de acordo com a teoria clássica da época. Como isto não aconteceu, Hurst chegou a uma conclusão revolucionária para época, de que as séries temporais destes fenômenos eram autocorrelacionadas [50].

2.3.1 Dinâmica Fractal

Fractais são objetos complexos que possuem duas propriedades características: auto-similaridade (pedaços do objeto assemelham-se ao todo) e tem a dimensão não inteira, menor que a dimensão do espaço euclidiano, no qual se encontra o fractal [50]. Como exemplo de objetos fractais, podemos citar a árvore, couve-flor, nuvens, neurônios, etc. [50,51,52].

Esses exemplos pertencem à classe dos fractais estocásticos, que possuem a propriedade de auto-similaridade em sentido estatístico, dentro dos limites da escala, onde o limite inferior representa à dimensão de partículas do sistema e o limite superior à dimensão linear do sistema. Os objetos geométricos (fractais determinísticos) podem ser construídos utilizando um processo iterativo e possuem propriedade de auto-similaridade em todas as escalas [50]. Na Figura 2.6 tem-se um exemplo de fractal determinístico, criado por Sierpinski Gasket.

Figura 2.6: Fractal Determinístico de Sierpinski Gasket [53]. Uma das maneiras de se obter um triângulo de Sierpinski é através do seguinte algoritmo: Passo 1: Comece com qualquer triângulo em um plano; Passo 2: Encolha o triângulo pela metade. Faça três cópias, e posicione cada triângulo de maneira que encoste nos outros dois em um canto; Passo 3: Repita o passo 2 para cada figura obtida, indefinidamente.



Nos fractais determinísticos a dimensão fractal pode ser determinada usando o seguinte procedimento: se $N(l)$ é o número de unidades da estrutura (ex. triângulos no caso do fractal Sierpinski Gasket, como mostrado na Figura 2.6) em escala l , a diminuição da escala b vezes gera um novo número de unidades estruturais,

$$N\left(\frac{l}{b}\right) = N(l)b^{D_f} \quad (2.3.6)$$

e a dimensão fractal D_f pode ser calculada usando a expressão:

$$D_f = \frac{\log \frac{N\left(\frac{l}{b}\right)}{N(l)}}{\log b} \quad (2.3.7)$$

Em fractais estocásticos a dimensão fractal pode ser obtida pela expressão:

$$V(R) \propto R^{D_f} \quad (2.3.8)$$

onde $V(R)$ é o volume da região de dimensão linear R e D_f a dimensão fractal, um número não inteiro e menor do que a dimensão euclidiana D do espaço em que o fractal se encontra [53].

Em séries temporais, o conceito fractal pode ser estendido como flutuações em múltiplas escalas do tempo. Essas flutuações temporais caracterizam-se pela auto-similaridade estatística da mesma maneira que os objetos fractais possuem a auto-similaridade nas várias escalas espaciais. Podem-se citar como exemplos de processos fractais os intervalos entre batimentos cardíacos em humanos [54], flutuações em atividade elétrica cerebral [55], dados financeiros [56,57], dados climáticos [14,60,61].

Uma série temporal $y(t)$ possui auto-similaridade com parâmetro α se

$$y(t) = b^\alpha y\left(\frac{t}{b}\right), \quad (2.3.9)$$

onde “=” significa a igualdade de propriedades estatísticas. Essa igualdade surge após mudanças de escalas de t e $y(t)$ usando os fatores diferentes: b para t ($t \rightarrow \frac{t}{b}$) e b^α para $y(t)$ ($y(t) \rightarrow b^\alpha y(t)$). O expoente α chama-se parâmetro de auto-similaridade [53].

Em uma série temporal que possui auto-similaridade, com um parâmetro $\alpha > 0$, as flutuações dentro de um intervalo (subconjunto da série) aumentam seguindo uma lei da potência, de acordo com o tamanho desse intervalo. Segundo Grabbe [48], a partir desta propriedade é possível mensurar correlações de longo alcance em séries temporais, utilizando técnicas que tem como base propriedades fractais. A invariância escalar, a auto-similaridade e a aleatoriedade são consideradas como sendo os três atributos fractais fundamentais.

2.3.2 Relação entre dimensão fractal e o expoente de Hurst

A dimensão fractal (D_f) foi relacionada com o expoente de Hurst por Mandelbrot e Wallis [49] através da seguinte fórmula:

$$D_f = 2 - H. \quad (2.3.10)$$

A dimensão fractal assume característica de preenchimento do espaço, podendo assumir valores não inteiros, ou seja, a medida que H diminui ($0 \leq H < 0,5$) D_f se aproxima de 2, logo o perfil se torna tão rugoso que é como se ele começasse a preencher o espaço como um plano. Se o expoente H aumenta ($0,5 < H < 1$) a dimensão diminui suavizando o perfil; se $H = 0,5$ a dimensão fractal é 1,5 representando movimento Browniano [48,60].

Diversas técnicas surgiram com o intuito de estimar o expoente de Hurst através de propriedades fractais. O objetivo do estudo de Delignieres et al. [61] foi avaliar o desempenho de alguns desses métodos. Foram testados os métodos *Power Spectral Density Analysis* [62], *Detrended Fluctuation Analysis* [63], *Rescaled Range Analysis* [47], *Dispersional Analysis* [64], *Maximum Likelihood Estimation* [65], e duas versões do *Scaled Windowed Variance Methods* [66,67]. Todos os métodos apresentaram diferentes vantagens e desvantagens, em termos de viés e de variabilidade. Segundo os autores, a escolha do melhor método para a estimativa do expoente de Hurst depende dos motivos científicos que motivaram a análise fractal.

Diante do grande número de trabalhos com aplicabilidade em variáveis climáticas [14,58,68,69,70,71], a simplicidade de aplicação e interpretação dos resultados e o baixo custo computacional exigido, escolhemos o *Detrended Fluctuation Analysis* (DFA) como método de estimativa do expoente de Hurst. Este método foi introduzido por Peng et al. [63] em um estudo para a análise de sequência de DNA para identificar a presença de correlações de longo alcance em séries temporais não estacionárias.

2.3.3 Uso de DFA em dados climáticos

A análise de correlações de longo alcance em processos climáticos é importante para validar modelos de previsão do clima. Os resultados de alguns estudos mostraram que os principais modelos não reproduziam corretamente as propriedades de escala detectadas em dados observados, precisando ser ajustados [68,72,73,74]. Medidas como DFA e *SampEn* se mostram importantes para a melhor compreensão do comportamento de variáveis climáticas no tempo e no espaço, tanto quanto a sua variabilidade quanto sua autocorrelação, e suas respectivas magnitudes. A partir destas medidas podemos ponderar a importância de cada variável

climática em possíveis previsões. Alguns autores mostraram que a variabilidade do expoente de Hurst em séries temporais de temperatura do ar variam conforme suas posições geográficas [75,76,77], indicando a necessidade da análise da distribuição espacial dos valores de expoentes.

Santos et al. [14] estudaram as propriedades temporais de séries de velocidade do vento horárias, em quatro estações meteorológicas do estado de Pernambuco, Brasil. Eles não observaram correlações entre os expoentes estimados com as características geográficas das estações (longitude, latitude e altitude da estação). Bakker e Hurk [78] realizaram estudo semelhante no oeste europeu, com observações colhidas em 16 estações meteorológicas. Eles também não encontraram correlação entre o expoente de Hurst estimado com a posição geográfica das estações, além da maritimidade. Das 16 estações estudadas, duas indicaram um comportamento aleatório nas séries, e uma outra indicou autocorrelação antipersistente, apontando para uma mudança climática na região. Esta última estação fica localizada na Groelândia, e o degelo no Oceano Ártico é um dos fatores apontados pelos autores como possível fator responsável por essa mudança.

Chen et al. [71] estimaram o expoente de DFA em séries de umidade relativa do ar média diária, em diferentes regiões climáticas da China. Seus resultados apontaram diferentes valores de α , nas diferentes regiões sob estudo. A partir destes resultados foi proposto um novo índice de classificação climática a partir do expoente de Hurst.

A correlação de longo alcance em séries temporais climáticas também foi alvo de estudo de Koscielny-Bunde et al. [69]. Eles aplicaram o DFA em séries de temperatura do ar máxima diárias em dados colhidos em 14 estações meteorológicas espalhadas pelo globo. Eles encontraram expoentes semelhantes para diferentes estações meteorológicas, localizadas em zonas climáticas distintas, e com diferentes escalas de tempo.

Fraedrich e Blender [68] buscaram, em seu estudo, comparar os expoentes de DFA para a temperatura do ar em diferentes ambientes. Para tal, se utilizou de informações históricas de estações meteorológicas localizadas na América do Norte, Europa, Austrália, América do Sul, África, Índia, Sudeste da Ásia, Oceano Índico e o Norte do Oceano Atlântico, em sua faixa tropical. Seus resultados apontaram que os

maiores expoentes estimados se encontram sob os oceanos, em áreas litorâneas e em regiões que sofrem forte influência climática de mares e oceanos. Por sua vez os menores valores foram observados sob o continente. Os autores concluíram que a continentalidade (ou maritimidade) é um elemento climático determinante para o alcance da autocorrelação temporal da temperatura do ar, onde locais mais próximos de mares e oceanos tendem a apresentar maiores valores de α em relação a locais mais distantes. Estes resultados são similares aos encontrados por Eichner et al. [76], onde tal relação também é observada.

Ao contrário dos resultados apresentados por Fraedrich e Blender [68] e Eichner et al. [76], Király e Jánosi [77] observaram na Austrália que o expoente de Hurst para a temperatura do ar média diária diminui com um maior distanciamento da linha do Equador. Em outras palavras, a latitude foi o fator climático com maior influência sobre o fenômeno. Porém a variabilidade do expoente apresentou comportamento oposto, aumentando com um maior distanciamento do Equador. Esta relação entre o expoente de Hurst (para séries de temperatura do ar média diária) e a latitude encontrada por Király e Jánosi [77] corroboram com os resultados encontrados por Tsonis et al. [79] e por Silva et al. [44], em estudos com focos similares.

A fim de avaliar se o aumento da temperatura do ar nos últimos anos é uma tendência ou uma flutuação natural, Lüdecke et al. [70] analisaram séries de recordes de temperatura do ar mensais em 2249 lugares em todo o mundo. As séries observadas possuem 100 anos de duração, e apresentaram correlação de longo alcance, medido com o DFA. Os resultados finais do estudo apresentaram que a chance de que as flutuações observadas sejam naturais está entre 40 e 90%, mas os autores não descartaram que ações antropogênicas tenham contribuído no aumento das temperaturas do ar.

2.4 Geoestatística

Trabalhando com dados de mineração de ouro, Krige [80] concluiu que as variâncias obtidas da abordagem clássica de amostragem não faziam sentido se não fosse considerada as distâncias entre as amostras. Baseado nessas observações, Matheron [81] desenvolveu a Teoria das Variáveis Regionalizadas. Ela foi definida como uma função espacial numérica, variando de um local para outro, apresentando

continuidade aparente e cuja variação não pode ser representada por uma função matemática. Inicialmente essa teoria foi aplicada a problemas voltados para a geologia e mineração, e recebeu o nome de geoestatística.

A Teoria das Variáveis Regionalizadas pressupõe que cada dado $z(x_i)$ é modelado como uma variável aleatória, que pode ser expressa pela soma de três componentes [81]:

- i) Componente estrutural, associada a um valor médio constante ou a uma tendência constante;
- ii) Componente aleatória, espacialmente correlacionada;
- iii) Ruído aleatório ou erro residual.

Se x representa uma posição de uma, duas ou três dimensões, então o valor da variável Z , em x , é dado por:

$$Z(x_i) = M(x) + \varepsilon'_x + \varepsilon_i, \quad (2.4.1)$$

onde $M(x)$ é uma função determinística que descreve a componente estrutural Z em x ; ε'_x é um termo estocástico que varia localmente e depende espacialmente de $M(x)$; e ε_i é um ruído aleatório não correlacionado, com média zero e variância σ^2 .

A geoestatística atua no termo estocástico ε'_x . Ela resume uma série de técnicas de interpolação espacial, utilizadas para a estimativa do valor de um atributo em locais não amostrados, a partir de pontos amostrados na mesma área ou região. A interpolação espacial converte dados de observações pontuais em campos contínuos, produzindo padrões espaciais que podem ser comparados com outras entidades espaciais contínuas. O raciocínio que está na base da interpolação é que, em média, os valores do atributo tendem a ser similares em locais mais próximos do que em locais mais afastados. Esse conceito também fundamenta a base das relações espaciais entre fenômenos geográficos, utilizando a correlação espacial como meio de diferença dos atributos estimados [82].

Existem diversos métodos na literatura para a realização de interpolações espaciais, onde cada um deles possui suas vantagens e desvantagens [83]. Como métodos de interpolação podemos listar o método Triangular [84], dos Polígonos [85], Distância Inversa [86,87], Vizinho mais Próximo [88], *Kriging* (ou Krigagem) [89] e *Inverse Distance Weighting* [90].

As estimativas de quase todos os métodos de interpolação espacial podem ser representadas como médias ponderadas dos dados amostrados. Todos eles compartilham a mesma fórmula de estimativa geral, como segue [91]:

$$\hat{z}(x_0) = \sum_{i=1}^n \lambda_i z(x_i), \quad (2.4.2)$$

onde \hat{z} é o valor estimado do atributo de um ponto de interesse x_0 , z é o valor observado no ponto amostrado x_i , λ_i é o peso atribuído ao ponto de amostragem e n representa o número de pontos amostrados utilizados para a estimativa.

Apaydin et al. [92] compararam seis técnicas de interpolação espacial (*Inverse Distance Weighting*, Interpolação Polinomial Global e Local, Spline, *Kriging* e *Cokriging*) para determinar qual destas melhor representa a distribuição espacial de 6 parâmetros climáticos diferentes (radiação solar, insolação, temperatura do ar, umidade relativa do ar, velocidade do vento e precipitação). Os dados utilizados nesses estudos foram observações feitas na região sudeste de Anatolia Project, na Turquia, no período de 1971 a 1999. Os resultados do estudo mostraram que o *Kriging* rendeu melhores resultados para a temperatura do ar, radiação solar, umidade relativa do ar, velocidade do vento e o Splines, para insolação e precipitação.

O *Kriging* mostrou-se eficiente na modelagem da precipitação mensal realizado na Bosnia e Herzegovina, com observações de 1960 a 2011. Segundo Nusret e Dug [93] o *Kriging* apresentou uma capacidade de adaptação à configuração do relevo e elevada precisão no cálculo da precipitação e de alguns índices climáticos em diferentes tamanhos de grade adotados. Ao ser comparado com o método *Inverse Distance Weighting*, o *Kriging* mostrou-se mais eficaz.

Luo et al. [94] compararam sete diferentes métodos de interpolação espacial para verificar qual destas produz melhores estimativas na modelagem espacial em séries de velocidade do vento, registrados em 190 estações meteorológicas em toda Inglaterra e País de Gales. Foram comparados quatro métodos determinísticos (*Trend Surface Analysis*, *Inverse Distance Weighting*, Interpolação Polinomial Local e *Spline*) e três métodos geoestatísticos (*Ordinary Kriging*, *Universal Kriging* e *Ordinary Cokriging*). Nos resultados observados pelos autores, os métodos geoestatísticos mostraram-se superiores aos determinísticos, sendo o *Cokriging* o que apresentou os melhores resultados. Eles também observaram que a confiabilidade nas me-

dições da variável em estudo, a distribuição de densidade e probabilidade das séries e a variabilidade espacial das mesmas influenciaram substancialmente a precisão dos diferentes métodos de interpolação.

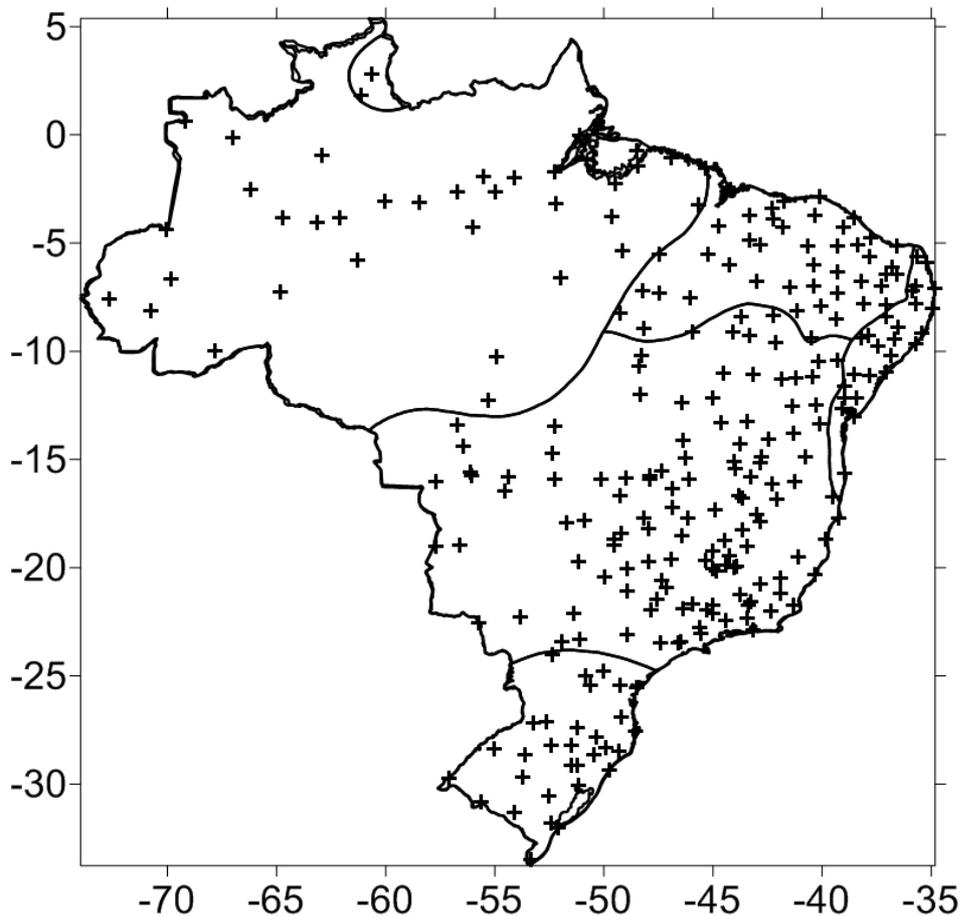
Diante de todos os estudos que compararam a eficiência dos métodos de interpolação espacial existentes, elegemos o *Kriging* como método de interpolação a ser utilizado em nosso trabalho devido a sua eficiência na realização das estimativas [92,93,94], e sua vasta utilização em dados climáticos [95,96,97,98,99].

3. MATERIAL E MÉTODOS

3.1 Dados

Os dados utilizados são séries históricas diárias de temperatura do ar mínima, média e máxima, umidade relativa média do ar e velocidade média do vento, obtidas pelo Instituto Nacional de Meteorologia (INMET) em 264 estações meteorológicas distribuídas no Brasil. Estes dados estão disponíveis para download pelo INMET no endereço eletrônico < <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>. A série de amplitude térmica foi obtida pela diferença entre as séries de temperaturas do ar máximas e mínimas. A disposição espacial das estações meteorológicas é observada na Figura 3.1. As séries são compostas por observações diárias realizadas entre os anos de 1990 e 2012.

Figura 3.1: Disposição espacial das estações meteorológicas do INMET localizadas no Brasil, conforme as diferentes regiões climáticas observadas na Figura 2.1.



As análises de DFA e Sample Entropy foram feitas no software Microsoft Visual Studio 6.0. Para ambas as técnicas são disponíveis códigos abertos, em linguagem C, para sua aplicação. O código para aplicação do DFA está disponível no endereço <<http://www.physionet.org/physiotools/dfa/dfa.c>> [100], e para a aplicação do Sample Entropy em <<http://www.physionet.org/physiotools/sampen/c/>> [101]. A interpolação espacial e a plotagem dos mapas foi feita utilizando o software Surfer versão 11.0.

3.2 Sample Entropy (SampEn)

O método *SampEn* introduzido por Richman e Moorman [33] é definido como sendo o logaritmo natural da probabilidade condicional de que duas sequências similares (dentro de um nível de tolerância r) para m pontos, permanecem similares para $m + 1$ pontos.

Seja $x(1), \dots, x(N)$ uma série temporal de tamanho N , o algoritmo de *SampEn* (m, r, N) é descrito como:

- i) Construir $N - m$ vetores de tamanho m , em que

$$x(i) = [x(i), x(i + 1), \dots, x(i + m - 1)], i = 1, \dots, N - m + 1; \quad (3.2.1)$$

- ii) Definir a distância d_m entre os vetores $x(i)$ e $x(j)$, onde

$$d_m[x(i), x(j)] = \max_{k=0, m-1} [|x(i + k) - x(j + k)|]; \quad (3.2.2)$$

- iii) Para cada $i = 1, \dots, N - m$; calcula-se

$$B_i^m(r) = \frac{B_i}{(N-m-1)}, \quad A_i^m(r) = \frac{A_i}{(N-m)}; \quad (3.2.3)$$

onde B_i é o número dos vetores $x(j)$ de tamanho m que são similares aos vetores $x(i)$ dentro da distância r : $d_m[x(i), x(j)] \leq r$ e A_i é o número dos vetores $x(j)$ de tamanho $(m + 1)$ que são similares aos vetores $x(i)$ dentro da distância r .

- iv) Calcula-se

$$B^m(r) = \frac{1}{N - m} \left(\sum_{i=1}^{N-m} B_i^m(r) \right), \quad (3.2.4)$$

$$A^m(r) = \frac{1}{N-m} \left(\sum_{i=1}^{N-m} A_i^m(r) \right),$$

onde $B^m(r)$ é a probabilidade de dois vetores serem similares para m pontos, $A^m(r)$ é a probabilidade de dois vetores serem similares para $(m + 1)$ pontos.

v) Por fim, calcula-se o índice *Sample Entropy*:

$$SampEn(m, r, N) = -\ln \left(\frac{A^m(r)}{B^m(r)} \right), \quad (3.2.5)$$

que representa a probabilidade condicional que de duas sequências que são similares para m pontos permanecem similares para $m + 1$ pontos (quando um dado consecutivo é adicionado).

A escolha do parâmetro m define o tamanho dos vetores inicialmente formados no algoritmo. Quando escolhermos o valor $m = 2$, por exemplo, estamos escolhendo mensurar as flutuações existentes em cada par de observações. Através do parâmetro r é que definimos se essa diferença em cada par será considerada significativa ou não. O parâmetro r usualmente é utilizado como percentual do desvio padrão dos dados. Por exemplo, se nossa série possui desvio padrão igual a 10 u.m. , e se adotarmos $r = 0,2$ e $m = 2$, estamos assumindo em nosso algoritmo que diferenças maiores que 2 u.m. , entre cada par de observações, será considerada como significativa. Quanto menor for o valor de r , maior será o rigor na estimativa da entropia. Em uma mesma série temporal, a variação de r fará com que tenhamos maiores estimativas de *SamEn* para os maiores valores de r adotados.

Sample Entropy é uma modificação do método *Approximate Entropy (ApEn)* [30]. Ambos os métodos servem para quantificar a complexidade em séries temporais não lineares, que foram amplamente usados em análise de processos fisiológicos [102] e séries climáticas [41]. Uma maior complexidade (menor regularidade) da série temporal gera o valor do *SampEn* mais alto [33]. De acordo com Shuangcheng et al. [41], a interpretação dos valores da estatística de *SampEn* considera uma série totalmente regular quando $SampEn = 0$ e para uma série totalmente irregular, $SampEn = 3$.

xidade de diferentes componentes do processo estocástico (que operam nas escalas distintas), e pode servir para diferenciar entre as séries temporais geradas pelos sistemas diferentes ou pelo mesmo sistema em condições diferentes [34]. Costa *et al.* [35] mostraram que a análise MSE permite uma melhor quantificação da complexidade estrutural de uma série temporal do que os métodos tradicionais baseados em entropia, que analisam a repetição dos padrões na série utilizando uma escala única [34].

3.4 Detrended Fluctuation Analysis (DFA)

Detrended Fluctuation Analysis é um método através do qual podemos identificar a presença de correlações de longo alcance em séries temporais não estacionárias. Este método foi introduzido por Peng *et al.* [63] para análise de sequências gênicas de DNA e vem sendo amplamente aplicado em diversos fenômenos, tais como variabilidade cardíaca [104,105], climatologia [14,58,106,107] e séries temporais financeiras [59,108,109]. Seja uma série temporal $y(i), i = 1, 2, \dots, N$, o procedimento DFA consiste na execução de quatro passos:

- i) O primeiro passo é a integração da série temporal

$$y(k) = \sum_{i=1}^k (y_i - \bar{y}), \quad (3.4.1)$$

em que \bar{y} é a média dos valores de y_i , para $i, k \in \{1, 2, \dots, N\}$;

- ii) Em seguida a série integrada, representada por $y(k)$, é dividida em intervalos de mesma amplitude n não sobrepostos;
- iii) Para cada intervalo de tamanho n , ajusta-se uma curva para representar a tendência local. O grau do polinômio irá determinar o tipo de processo DFA aplicado, para uma ajuste polinomial de grau m , chama-se de DFA- m . Em nosso trabalho utilizamos apenas o DFA-1, onde o ajuste para a tendência local é dado através de uma reta para o intervalo n , esta reta é comumente representado por $y_n(k)$. Por conseguinte, a série $y(k)$ é subtraída de $y_n(k)$ para cada amplitude de tamanho n . Assim, a medida da flutuação da série para o intervalo de tamanho n é dada por:

$$F(n) = \sqrt{\frac{1}{N} \sum_{k=1}^N [y(k) - y_n(k)]^2}; \quad (3.4.2)$$

- iv) Por fim, temos que $F(n) \sim n^\alpha$, em que α é o expoente de correlação de longo alcance, esta relação pode ser linearizada em um gráfico $\log F(n)$ versus $\log n$, é representada por uma reta de inclinação α , que é o expoente desejado.

Para diminuir a influência da sazonalidade, o DFA foi aplicado nas séries temporais de anomalias obtidas através de uma normalização diária das mesmas, onde os valores de média e desvio padrão utilizados em cada normalização, são correspondente à data do calendário em que ocorreu a observação. Por exemplo, na normalização da observação da temperatura do ar máxima em 1 de janeiro de 2012, devemos subtrair desta observação a média da temperatura do ar máxima de todos os dias 1 de janeiro do período estudado, e após, dividir o resultado pelo desvio padrão de todos os dias 1 de janeiro do mesmo período. A essa nova série daremos o nome de “anomalia”. Através desse procedimento elimina-se grande número de oscilações, obtendo assim, uma série estacionária, adequada para aplicação do método

A vantagem do método DFA reside no fato de conseguir eliminar tendências de diferentes ordens e detectar tendências com correlações polinomiais que, por vezes, mascaram a natureza das correlações. Segundo Liu et al. [110], a caracterização de um processo de memória longa (persistente) é dada quando o expoente $\alpha > 0.5$, temos então que os valores grandes (ou pequenos), têm maior probabilidade de serem seguidos por valores grandes (ou pequenos), por exemplo, dias com umidade relativa média do ar alta tendem a ser seguidos por dias com umidade relativa média do ar alta. Para séries de tempo não correlacionadas (ruído branco) temos $\alpha = 0.5$ e para $\alpha < 0.5$, a série exibe uma correlação de longo alcance antipersistente, significando que os valores grandes (ou pequeno) têm maior probabilidade de serem seguidos por valores pequenos (ou grandes).

3.5 Kriging

Kriging (muitas vezes traduzido como Krigagem) é um método de regressão usado em geoestatística para aproximar ou interpolar dados. O *Kriging* pode ser entendido como uma predição linear ou uma forma da Inferência Bayesiana. Parte do princípio que pontos próximos no espaço tendem a ter valores mais parecidos do que pontos mais afastados. A técnica de Krigagem assume que os dados recolhidos de uma determinada população se encontram correlacionados no espaço [111].

3.5.1 Semivariância e Variograma

O semivariograma (ou simplesmente variograma) é o método geoestatístico para diagnosticar a presença da correlação entre as unidades amostradas. Segundo Webster [112], os semivariogramas são preferidos para caracterizar a estrutura de continuidade espacial da característica avaliada, por exigirem hipóteses de estacionaridade menos restritivas (hipótese intrínseca). O semivariograma representa uma função de semivariâncias em relação às respectivas distâncias. A semivariância é definida como a metade da variância de diferenças entre observações de uma variável aleatória Z , separadas por uma distância h . Assim, valores baixos indicam menor variabilidade (maior similaridade).

Segundo Journel e Huijbregts [113], a função variograma, denominada de $2\gamma(h)$, é a esperança matemática do quadrado da diferença entre pares de pontos separados por uma distância (h),

$$2\gamma(h) = E\{[Z(x) - Z(x + h)]^2\}. \quad (3.5.1)$$

A metade da função variograma é denominada de função semivariograma. O estimador da semivariância $[\hat{\gamma}(h)]$ é igual a média aritmética das diferenças ao quadrado entre pares de valores experimentais, em todos os pontos separados pela distância h .

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x) - Z(x + h)]^2, \quad (3.5.2)$$

onde $[\hat{\gamma}(h)]$ é a semivariância estimada para cada distância (h) , $N(h)$ é o número de pares de pontos separados por uma distância h , $Z(x)$ é o valor da variável regionalizada no ponto x e $Z(x+h)$ é o valor no ponto $x+h$.

O gráfico entre $\gamma(h)$ e h é conhecido como variograma experimental, o qual permite interpretar a continuidade espacial da variável regionalizada [91].

3.5.2 Modelos de Semivariogramas

Existem vários modelos de ajuste aplicáveis a diferentes fenômenos com continuidade espacial. Estes modelos, chamados de modelos teóricos, devem fornecer soluções estáveis para o estimador linear – *Kriging*. Isto quer dizer que as covariâncias têm de ser definidas positivamente, ou seja, a matriz de covariância utilizada na Krigagem pode ser invertida. A condição de positividade do modelo limita o conjunto de funções usadas na modelagem do semivariograma experimental [112]. Apresentamos o modelo de algumas funções de ajuste da correlação, e seus respectivos gráficos são vistos na Figura 3.3.

- Linear (Kitanidis [114]) $\rightarrow \gamma(h) = C(h)$; (3.5.3)

- Exponencial (Cressie [115]) $\rightarrow \gamma(h) = C[1 - e^{-h}]$; (3.5.4)

- Gaussiano (Pannatier [116]) $\rightarrow \gamma(h) = C[1 - e^{-h^2}]$; (3.5.5)

- Potência (Pannatier [116]) $\rightarrow \gamma(h) = C[h^n]$, (3.5.6)
onde $0 < n < 2$, quando $n = 1$ este se torna um modelo Linear;

- Quadrático (Alfaro [117]) $\rightarrow \gamma(h) = \begin{cases} C[2h - h^2] & h < 1, \\ C & h \geq 1 \end{cases}$; (3.5.7)

- Racional Quadrático (Cressie [115]) $\rightarrow \gamma(h) = C \left[\frac{h^2}{1+h^2} \right]$; (3.5.8)

- Wave (Cressie [115]) $\rightarrow \gamma(h) = C \left[1 - \frac{\text{sen } h}{h} \right]$; (3.5.9)

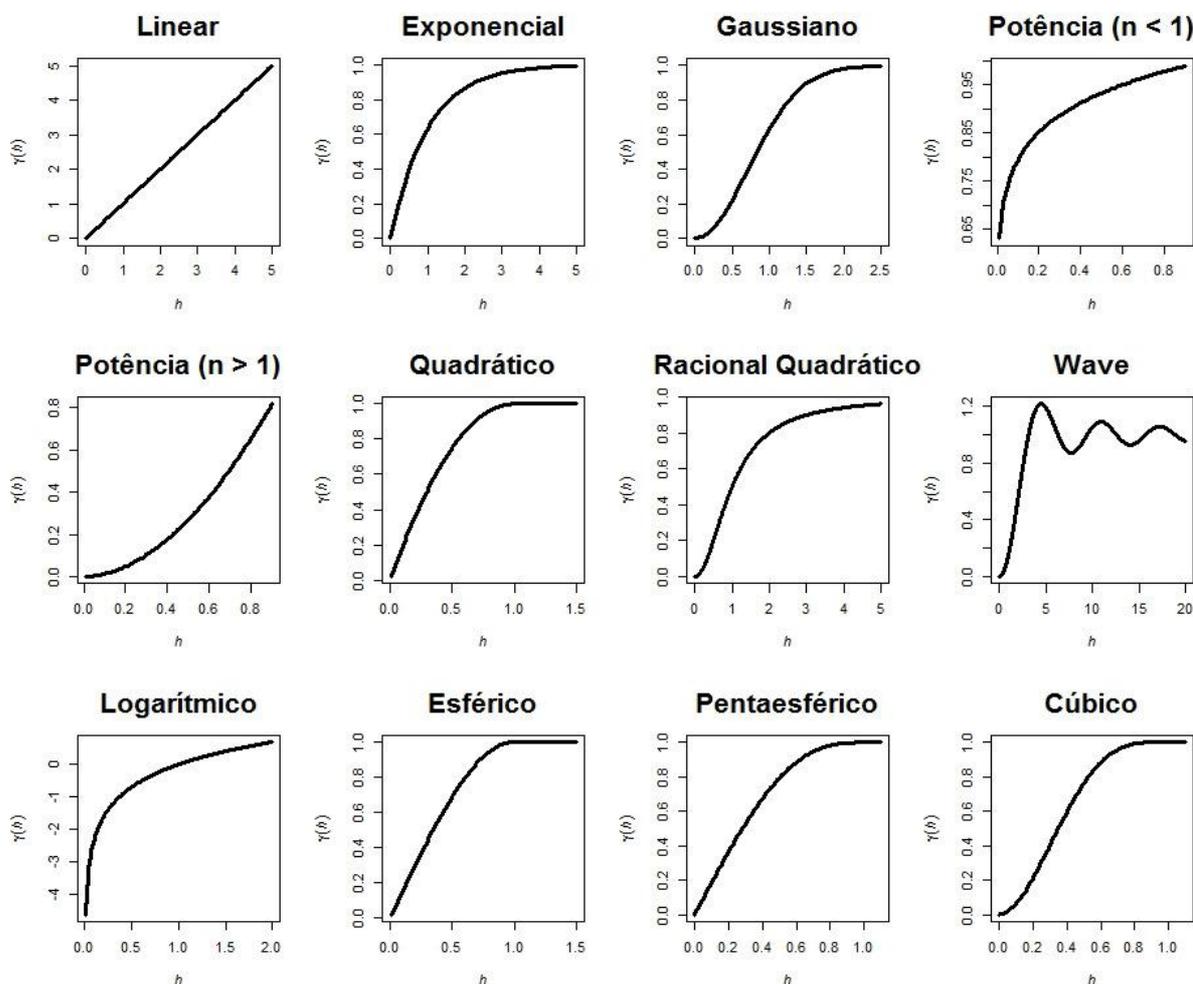
- Logarítmico (Kitanidis [114]) $\rightarrow \gamma(h) = C[\ln(h)]$, $h > 0$; (3.5.10)

- Esférico (Pannatier [116]) $\rightarrow \gamma(h) = \begin{cases} C[1,5 h - 0,5 h^3] & h < 1; \\ C & h \geq 1; \end{cases} \quad (3.5.11)$

- Pentaesférico (Olea [111]) $\rightarrow \gamma(h) = C(1,87 h - 1,25 h^3 + 0,375 h^5); \quad (3.5.12)$

- Cúbico (Olea [111]) $\rightarrow \gamma(h) = C(7 h^2 - 8,75 h^3 + 3,5 h^5 - 0,75 h^7). \quad (3.5.13)$

Figura 3.3: Gráficos de alguns modelos de variogramas.

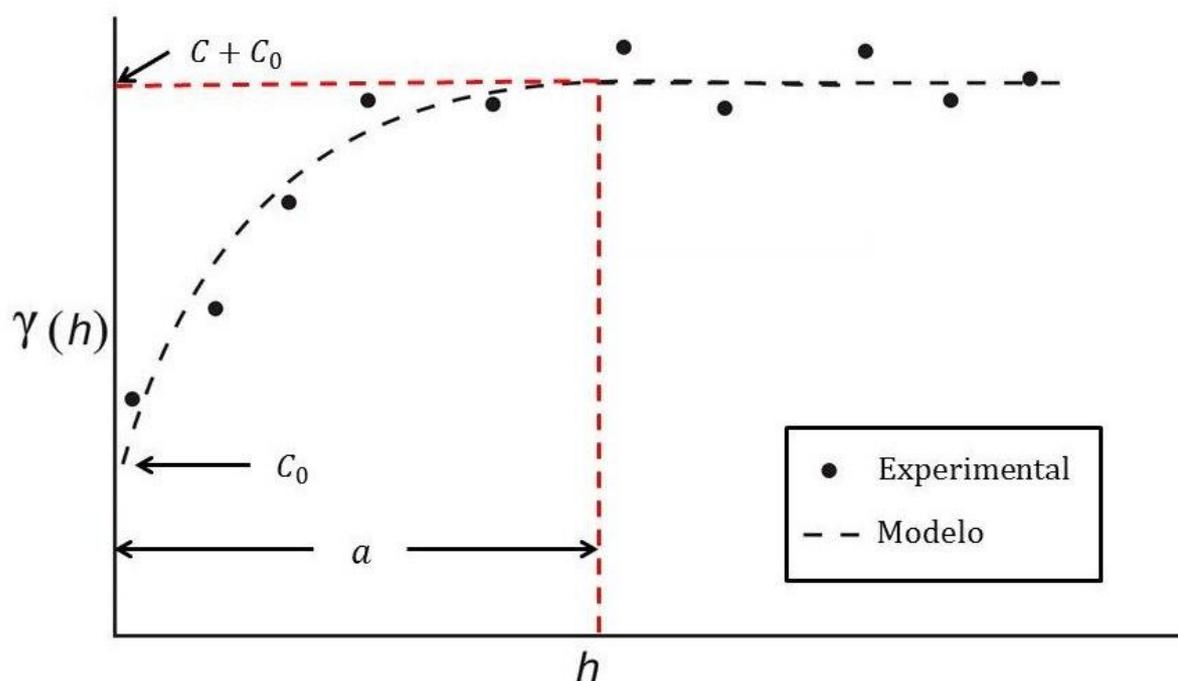


Através do semivariograma experimental, o pesquisador é capaz de definir o modelo que melhor descreve o comportamento dos dados no espaço [113]. Em seguida, sua preocupação se volta para o ajuste da função matemática ao semivariograma experimental ou aos dados [112].

A medida que h aumenta $\gamma(h)$ também aumenta, pois é de se esperar que amostras tiradas a uma pequena distância entre si tenham a parcela $[Z(x) - Z(x + h)]^2$, da Equação (3.5.1), menores que aquelas tiradas a distâncias maiores. O ajuste do modelo matemático aos dados no gráfico, define os parâmetros do semivario-

grama, que são: efeito pepita (C_0), que é o valor de $\gamma(h)$ quando $h = 0$; o alcance (a) da dependência espacial, que é o valor de h a partir do qual a função se estabiliza; e o patamar ($C + C_0$), valor de $\gamma(h)$ para determinado alcance (a), cujo valor é aproximadamente igual à variância dos dados (se existir) e é obtido pela soma do efeito pepita e a variância estrutural (C) (Figura 3.4).

Figura 3.4: Semivariograma experimental e modelo matemático ajustado



3.5.3 Inferência Espacial – *Kriging*

Conforme descrito por Isaak e Serivastava [85], existem vários tipos de Krigagem: *Kriging* pontual, ordinário, universal, de blocos, etc. Neste trabalho foi adotada a Krigagem de bloco. Ela envolve estimativas de valores da variável regionalizada para uma subárea da área total. Segundo Burgess e Webster [118], a Krigagem de bloco é apropriada (em relação a Krigagem pontual), para situações em que a informação média é mais útil do que o valor exato no ponto.

Os estimadores de Krigagem são variantes da equação (3.5.14), que é uma ligeira modificação da equação (2.4.2), como segue.

$$\hat{Z}(x_0) - \mu = \sum_{i=1}^n \lambda_i [Z(x_i) - \mu(x_0)], \quad (3.5.14)$$

onde μ é uma média estacionária conhecida, assumida ser constante ao longo de todo o domínio e calculada como sendo a média dos dados. O parâmetro λ_i é o peso da Krigagem; n é o número de pontos amostrados e usados na realização das estimativas e depende do tamanho da grade (bloco) de pesquisa; e $\mu(x_0)$ é a média das amostras contidas na grade de pesquisa [91].

Os pesos são estimados através da minimização da variância

$$\begin{aligned} \text{Var}[\hat{Z}(x_0)] &= E \left[\{\hat{Z}(x_0) - Z(x_0)\}^2 \right] \\ &= E \left[(\hat{Z}(x_0))^2 + (Z(x_0))^2 - 2 \hat{Z}(x_0)Z(x_0) \right] \\ &= \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j C(x_i - x_j) + C(x_0 - x_0) - 2 \sum_{i=1}^n \lambda_i C(x_i - x_0) \end{aligned} \quad (3.5.15)$$

onde $Z(x_0)$ é o valor esperado no ponto x_0 ; n representa o número de observações a serem incluídas na estimativa; e $C(x_i - x_j) = \text{Cov}[Z(x_i), Z(x_j)]$ [85].

A Krigagem ordinária se diferencia em relação à Krigagem simples por não necessitar da média para se encontrar os pesos que minimizam a variância do erro da estimativa. No entanto, apresenta algumas exigências, tal como a estimativa da média local, que resulta na soma unitária dos pesos λ_i . Sua formula geral é dada por [113]

$$\hat{Z}(x_0) = \sum_{i=1}^n \lambda_i Z(x_i). \quad (3.5.16)$$

Os pesos ($\lambda_i, i = 1, \dots, n$) são obtidos da resolução de um sistema de equações lineares denominado sistema de Krigagem. Como se deseja um estimador não tendencioso considera-se

$$E[Z(x_0) - \hat{Z}(x_0)] = 0. \quad (3.5.17)$$

Essa relação impõe que as duas médias sejam iguais; portanto aplicando-se a equação (3.5.16) em (3.5.17), obtém-se

$$E[Z(x_0)] = E \left[\sum_{i=1}^n \lambda_i Z(x_i) \right] \Rightarrow m = \sum_{i=1}^n \lambda_i m. \quad (3.5.18)$$

Deve-se considerar a condição de não enviesamento para $\hat{Z}(x_0)$ como

$$\sum_{i=1}^n \lambda_i = 1. \quad (3.5.19)$$

Journal [119] mostra que, minimizando a variância do erro $Var[Z(x_0) - \hat{Z}(x_0)]$, sob a condição expressa pela equação (3.5.19), os valores λ_i são obtidos a partir do seguinte sistema de equações, denominado sistema de Krigagem ordinária

$$\begin{cases} \sum_{i=1}^n \lambda_i C(x_i - x_j) - \nu = C(x_0 - x_j), i = 1, \dots, n \\ \sum_{i=1}^n \lambda_i = 1 \end{cases} \quad (3.5.20)$$

onde $C(x_i - x_j)$ refere-se à função de covariância correspondente a um vetor h , com origem em x_i e extremidade no ponto a ser estimado x_0 ; ν é o multiplicador de Lagrange necessário para a minimização do erro.

Em termos matriciais, as equações (3.5.20) são representadas como

$$\begin{bmatrix} C(x_1 - x_1) & C(x_1 - x_2) & \dots & C(x_1 - x_n) & 1 \\ C(x_2 - x_1) & C(x_2 - x_2) & \dots & C(x_2 - x_n) & 1 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ C(x_n - x_1) & C(x_n - x_2) & \dots & C(x_n - x_n) & 1 \\ 1 & 1 & \dots & 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \\ \nu \end{bmatrix} = \begin{bmatrix} C(x_0 - x_1) \\ C(x_0 - x_2) \\ \vdots \\ C(x_0 - x_n) \\ 1 \end{bmatrix} \quad (3.5.21)$$

Chamando de \mathbf{A} a matriz das semivariâncias dos valores amostrados envolvidos na estimativa de $\hat{Z}(x_0)$; $\boldsymbol{\lambda}$ a matriz coluna que contém os pesos λ_i e o multiplicador de Lagrange e \mathbf{C} a matriz coluna das semivariâncias entre os valores amostrados e o ponto a ser estimado, tem-se

$$\mathbf{A} = \boldsymbol{\lambda} \mathbf{C}. \quad (3.5.22)$$

Portanto,

$$\boldsymbol{\lambda} = \mathbf{A}^{-1} \mathbf{C}. \quad (3.5.23)$$

Observamos que:

- i) A matriz \mathbf{A} é simétrica e possui diagonal principal igual a zero, ou igual ao valor do efeito pepita;

- ii) Os valores 1 que aparecem nas matrizes **A** e **C** são consequência do multiplicador de Lagrange;
- iii) O sistema deve ser resolvido para cada estimativa $\hat{Z}(x_0)$ e para cada variação do número de amostras envolvidas na estimativa.

A correspondente variância minimizada do erro, denominada variância de Krigagem ordinária σ_E^2 , é dada pela expressão [119]

$$\sigma_E^2 = Var[Z(x_0) - \hat{Z}(x_0)] = C(0) - \sum_{i=1}^n \lambda_i C(x_i - x_0) - v = \mathbf{C}^t \boldsymbol{\lambda} \quad (3.5.24)$$

4. RESULTADOS E DISCUSSÃO

Todos os resultados obtidos para as análises de DFA e *Sample Entropy*, assim como as médias e desvios das observações, foram interpolados e explicitados espacialmente sob o mapa do Brasil. Esta interpolação deu-se com o uso do *Kriging*, e os variogramas obtidos em cada interpolação podem ser vistos no Apêndice. Foram obtidos os valores das médias e desvios padrão de cada variável em estudo, em cada uma das 264 estações meteorológicas, distribuídas espacialmente no território brasileiro, como já visto na Figura 3.1.

O expoente de Hurst, neste trabalho medido através do DFA, é uma estatística que nos forneceu a ideia de persistência (ou antipersistência) em nossas séries. Esta persistência reflete a autocorrelação de longo alcance de nossas variáveis, por exemplo, se dias quentes tendem a ser sucedidos por dias também quentes (persistência), ou se dias quentes tendem a serem sucedidos por dias frios (antipersistência), e principalmente, se este comportamento irá perdurar ao longo do tempo (correlação de longo alcance). Esta estatística encontra-se entre 0 e 1, onde valores acima de 0,5 indicam persistência e abaixo, antipersistência. Para um expoente α igual a 0,5 temos caracterizado uma série totalmente aleatória. Quanto mais próximo dos extremos, mais “forte” será a autocorrelação, por exemplo, quanto mais próximo de 1 for a estimativa do expoente de Hurst, mais duradouro será este comportamento. Todas as séries estudadas neste trabalho mostraram-se persistentes ($\alpha > 0,5$), variando apenas em sua magnitude.

A entropia das séries climáticas em estudo foi estimada com a aplicação da técnica *Sample Entropy*. Esta medida nos deu o grau de desordem das nossas séries temporais, em outras palavras, medimos a complexidade (variabilidade) das mesmas. Esta estatística varia no intervalo de 0 a 3, onde o zero é resultante de séries totalmente regulares, e 3, de séries completamente desordenadas. Todas as estimativas de *Sample Entropy* foram feitas admitindo $m = 2$, $r = 0,2$ e $\tau = 1, 2, 3, \dots, 30$. Ou seja, estimamos para as 264 séries valores de *SampEn* na escala de 1 a 30 dias.

Imagine um ambiente em que dias quentes são sempre seguidos por dias frios, e dias frios sempre são seguidos por dias quentes. Do ponto de vista da análise

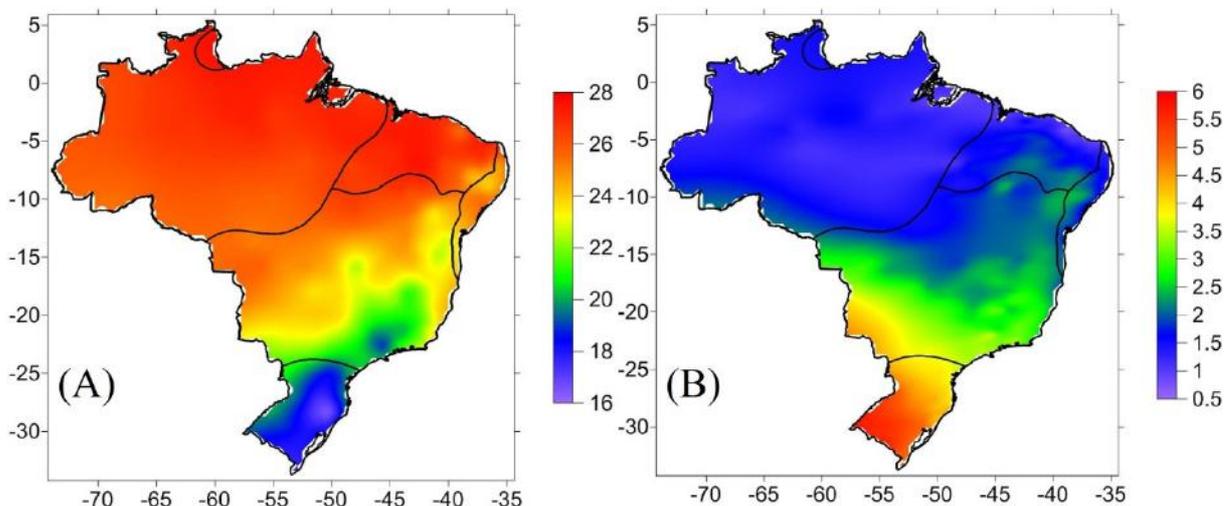
se climática através do DFA, esta seria caracterizada como uma série antipersistente. Porém, na visão da entropia (*Sample Entropy*), esta é uma série completamente regular, onde sempre sabemos que um dia frio será seguido por um dia quente, e vice versa. Esta regularidade pode acontecer em janelas da série temporal, por exemplo, se um dia frio sempre for seguido por dois dias quentes. Assim, avaliamos nossas séries em múltiplas escalas, onde possíveis padrões poderão ser observados até o intervalo de um mês.

4.1 Temperatura média do ar

A temperatura média diária do ar apresentou maiores valores nas regiões Norte e Nordeste do Brasil (Figura 4.1 A), nas porções de clima Equatorial e Tropical Zona Equatorial. Este resultado condiz com o conhecimento prévio sobre o fenômeno em estudo, onde se esperam maiores temperaturas do ar nas regiões mais próximas a linha do Equador. As regiões mais quentes apresentaram temperatura média diária do ar variando entre 26 e 30 °C. A região de clima Temperado, mais distante da linha do Equador, foi a que apresentou menores valores médios da temperatura média diária do ar. Conforme Mendonça e Danni-Oliveira [2] e Varejão-Silva [19] a temperatura média do ar diminui em áreas com maior altitude. Antiguidade da formação do relevo e da ausência de dobramentos modernos faz com que o Brasil apresente baixas altitudes [29], que acabam interferindo apenas de forma pontual no clima de algumas localidades. Em uma visão mais ampla do fenômeno, não se observam influências da altitude sobre os valores médios da temperatura média do ar.

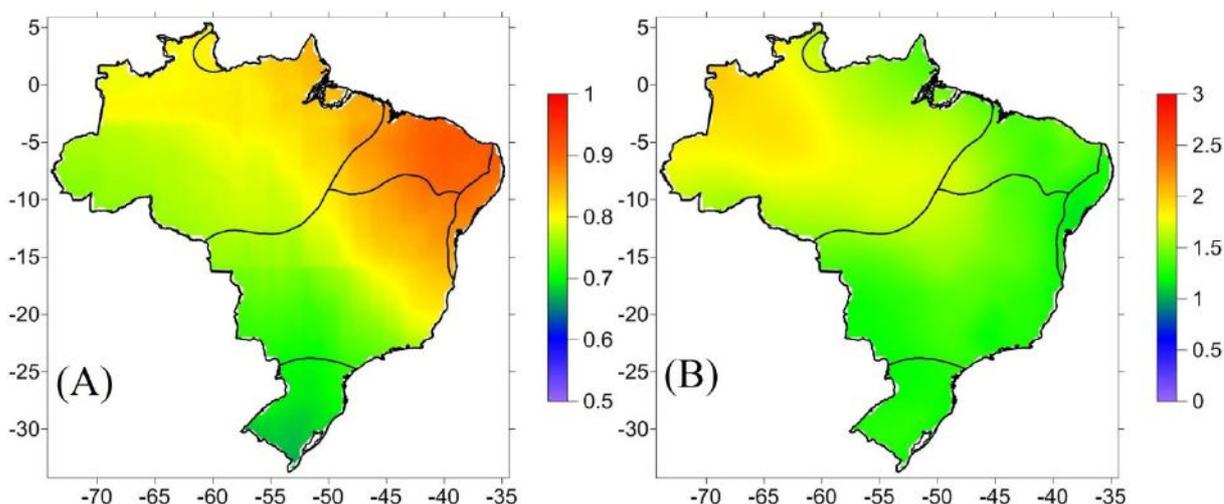
O desvio padrão desta mesma variável (Figura 4.1 B) também apresentou uma relação com a latitude, onde as maiores variabilidades foram observadas em locais mais distantes do Equador. Logo, nota-se que as maiores variabilidades da temperatura média do ar está localizada nas regiões com menores médias da mesma, ou seja, há uma relação inversamente proporcional na distribuição espacial de ambas as estatísticas. Ou seja, a latitude influencia a temperatura média do ar de tal forma que, quão mais próximo da linha do Equador observarmos, iremos obter maiores temperaturas médias diárias e uma menor variabilidade da mesma.

Figura 4.1: Média (A) e desvio padrão (B) da temperatura média diária do ar no Brasil, no período de 1990 a 2012.



Notam-se faixas bem definidas da persistência climática (α) para a temperatura média diária do ar (Figura 4.2 A), os valores de α aumentaram com a menores latitude e longitude, formando faixas diagonais com os diferentes valores da estatística. Em média, o expoente de Hurst estimado para o Brasil foi de 0,79, apontando um considerável alcance da autocorrelação para a temperatura média do ar. Na região de clima Temperado encontram-se os menores valores da estatística, em torno de 0,6, indicando uma curta autocorrelação. O maior alcance da autocorrelação foi observado na região Nordeste, nas porções de clima Tropical Zona Equatorial e Tropical Nordeste Oriental, onde foram estimados os maiores valores de α .

Figura 4.2: Estimativas dos expoentes DFA (A) e coeficientes de *Sample Entropy* (B) das séries de temperatura média diária do ar no Brasil, no período de 1990 a 2012.



A entropia (*SampEn*) estimada para as séries de temperatura média diária do ar podem ser observadas na (Figura 4.2 B). As diferenças nos valores da entropia nas diferentes escalas foram bastante sutis. Nota-se que pra $\tau = 1$ uma menor homogeneidade nos valores de entropia ao longo do território brasileiro, com média de 1,39. Na região Norte e em parte do Centro-Oeste (região de clima Tropical), foi observada uma faixa sobre o território brasileiro com entropia em torno de 2, enquanto no resto do país este valor variou entre 1 e 1,5.

Este comportamento manteve-se similar a partir de valores de $\tau > 1$, ou seja, para a observação do comportamento da entropia a partir da escala de dois dias. Esta faixa que corta a região de clima Tropical, com maiores valores entrópicos para a temperatura média diária do ar, observada na Figura 4.3, segue a mesma direção da massa de ar Equatorial Continental (Figura 2.5). Segundo Lutgens e Tarbut [120], esta é uma massa quente e úmida que domina a porção noroeste da Amazônia quase todo ano. Na China, Shuangcheng et al. [41], também encontraram uma relação entre as estimativas do *SampEn* e a influências das massas de ar, porém os maiores valores entrópicos foram observados em regiões de interação de diversas massas de ar, enquanto os nossos resultados apontaram o oposto, menores valores da estatística em regiões de interação de diversas massas de ar. Não observamos no Brasil um relação entre a entropia estimada com os demais fatores climáticos (latitude, altitude, maritimidade, vegetação, etc.). Esta ausência de correlação entre a entropia e estes fatores também foi observado por Zhao et al. [43], na China, onde ele utilizou o *ApEn* para estimar a entropia das séries de temperatura do ar.

A Figura 4.4 mostra, através do Error plot ($\alpha = 5\%$), a variação do valor médio da entropia para o Brasil e em suas diferentes regiões climáticas, nas diferentes escalas de τ . Observamos um nítido aumento da estatística de $\tau = 1$ para $\tau = 2$ (Figura 4.4 A), seguida de uma estabilização da mesma para escalas maiores que 2. A região com clima Tropical Brasil Central (Figura 4.4 D) apresentou comportamento semelhante. A região de clima Temperado (Figura 4.4 C) também apresentou um nítido aumento da estatística na escala de $\tau = 1$ para $\tau = 2$, porém, seguida de uma suave tendência de decréscimo da mesma. Os valores da entropia nas demais zonas climáticas pouco variaram.

Figura 4.3: Coeficiente de entropia (Sample Entropy) das séries de temperatura média diária do ar no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).

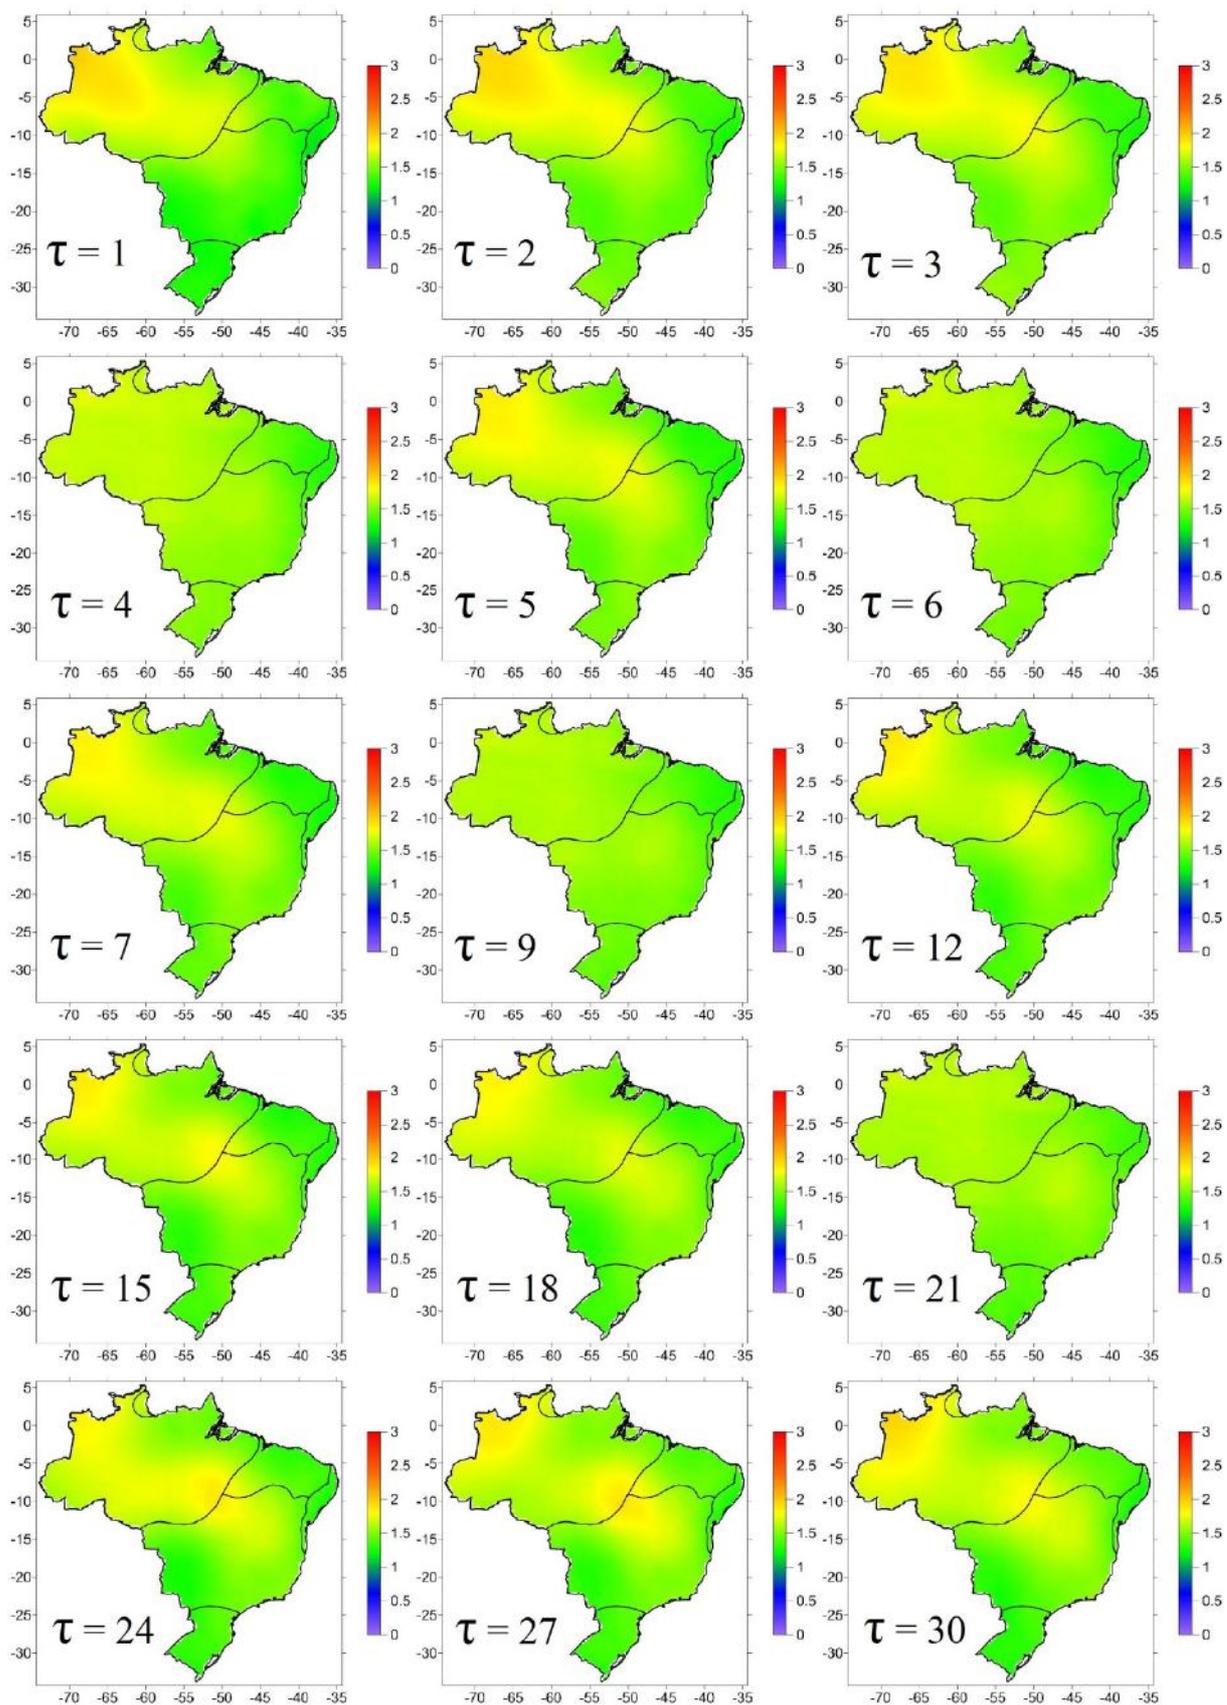
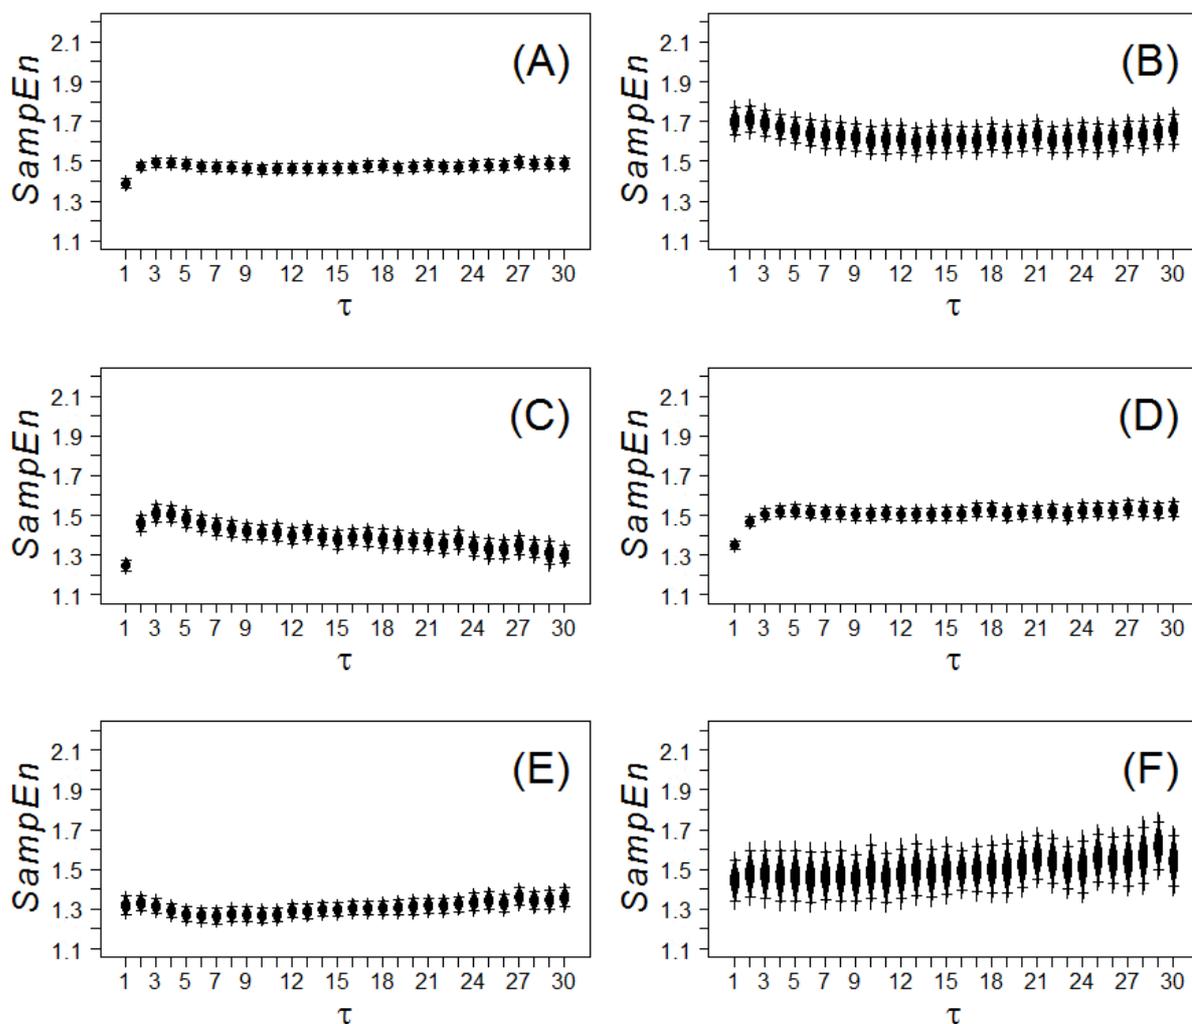


Figura 4.4: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (*Multiscale Sample Entropy*) das séries de temperatura média diária do ar no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).

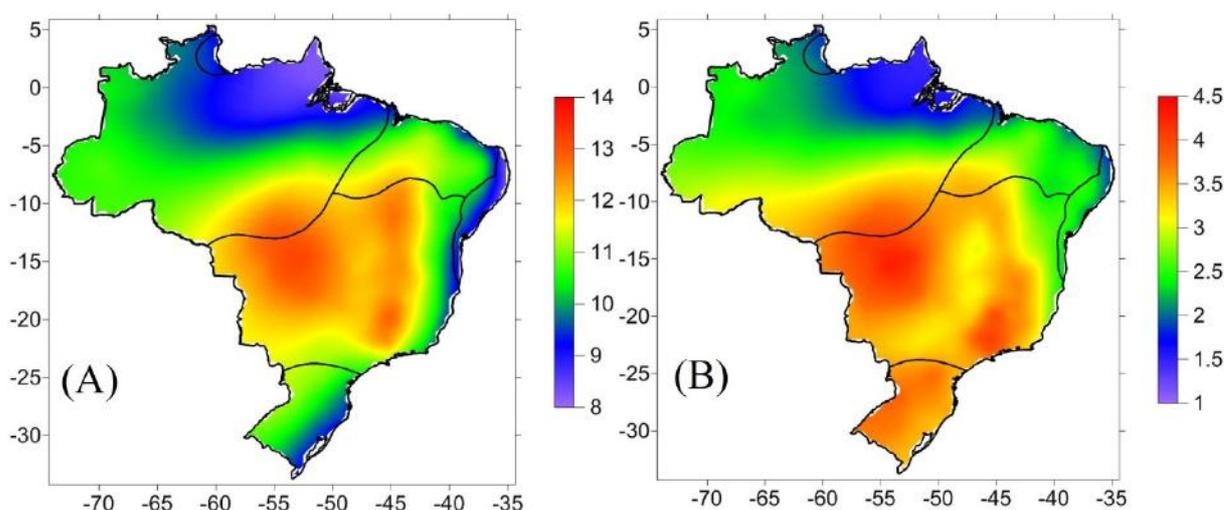


4.2 Amplitude térmica do ar

A amplitude térmica diária (Figura 4.5 A) apresentou as menores médias (6 a 8 °C) no litoral do Nordeste e do Sul, e em uma porção da região Norte do país (Amapá, norte do Pará e nordeste do Amazonas). Estes locais fazem parte das regiões de clima Tropical Nordeste Oriental, Temperado, e Tropical, respectivamente. Em localidades costeiras, os ventos vindos do oceano funcionam como moderadores da temperatura do ar, diminuindo a amplitude térmica local, explicando os baixos valores médios no litoral das regiões Sul e Nordeste. As maiores médias foram ob-

servadas na região Centro-Oeste, Minas Gerais, sul do Piauí e região oeste da Bahia, compreendido em sua maior parte na região de clima Tropical Brasil Central. O desvio padrão (Figura 4.5 B) apresenta um comportamento similar a média, com os menores desvios localizados sob as áreas de menor média. Destaca-se a região de clima Temperado, que apresenta valores de desvio relativamente altos, comparadas aos valores médios da mesma região.

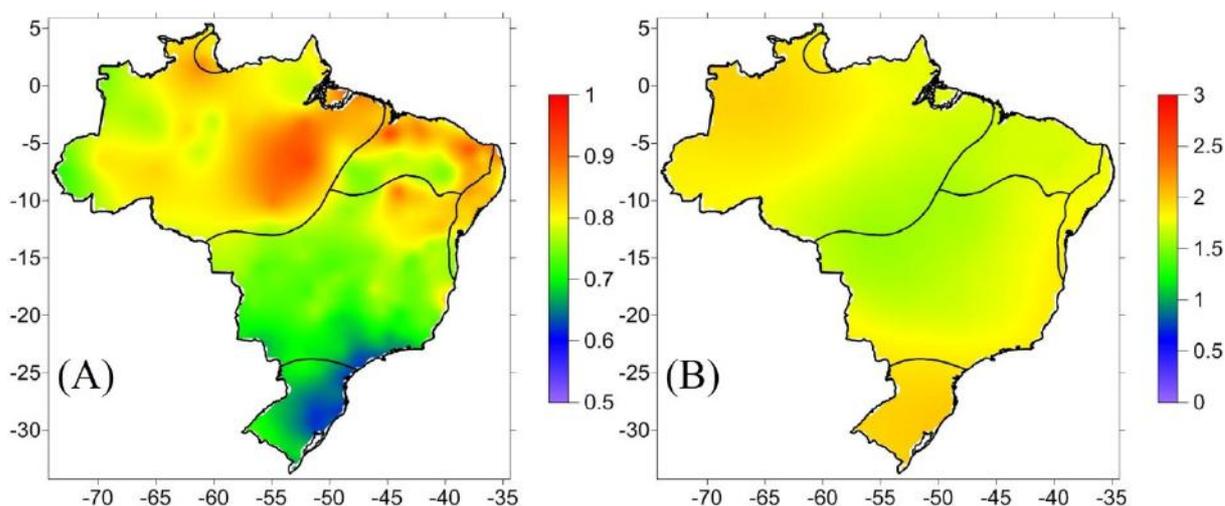
Figura 4.5: Média (A) e desvio padrão (B) da amplitude térmica diária do ar no Brasil, no período de 1990 a 2012.



Conforme Lutgens e Tarbuck [120], o ciclo anual de temperatura do ar reflete claramente a variação da radiação solar incidente ao longo do ano, fazendo que na faixa entre os trópicos de Câncer e Capricórnio, as temperaturas do ar médias variem pouco durante o ano. Uma consequência deste comportamento deve se refletir na amplitude térmica, fazendo com que a amplitude diminua com a proximidade da linha do Equador, porém, em nossos resultados não observamos tal relação. Varejão-Silva [19] e Pereira et al. [28] citam que os oceanos funcionam como agentes reguladores da temperatura do ar, uma vez que o aquecimento e resfriamento dos mares e dos continentes dá-se de maneira distinta, sendo que o continente aquece e resfria de forma mais rápida que o oceanos. Essa característica faz com que regiões litorâneas apresentem menores amplitudes térmicas. Tal comportamento foi observado em nossos resultados (Figura 4.5 A), onde a região litorânea apresentou as menores médias de amplitude térmica diária no Brasil.

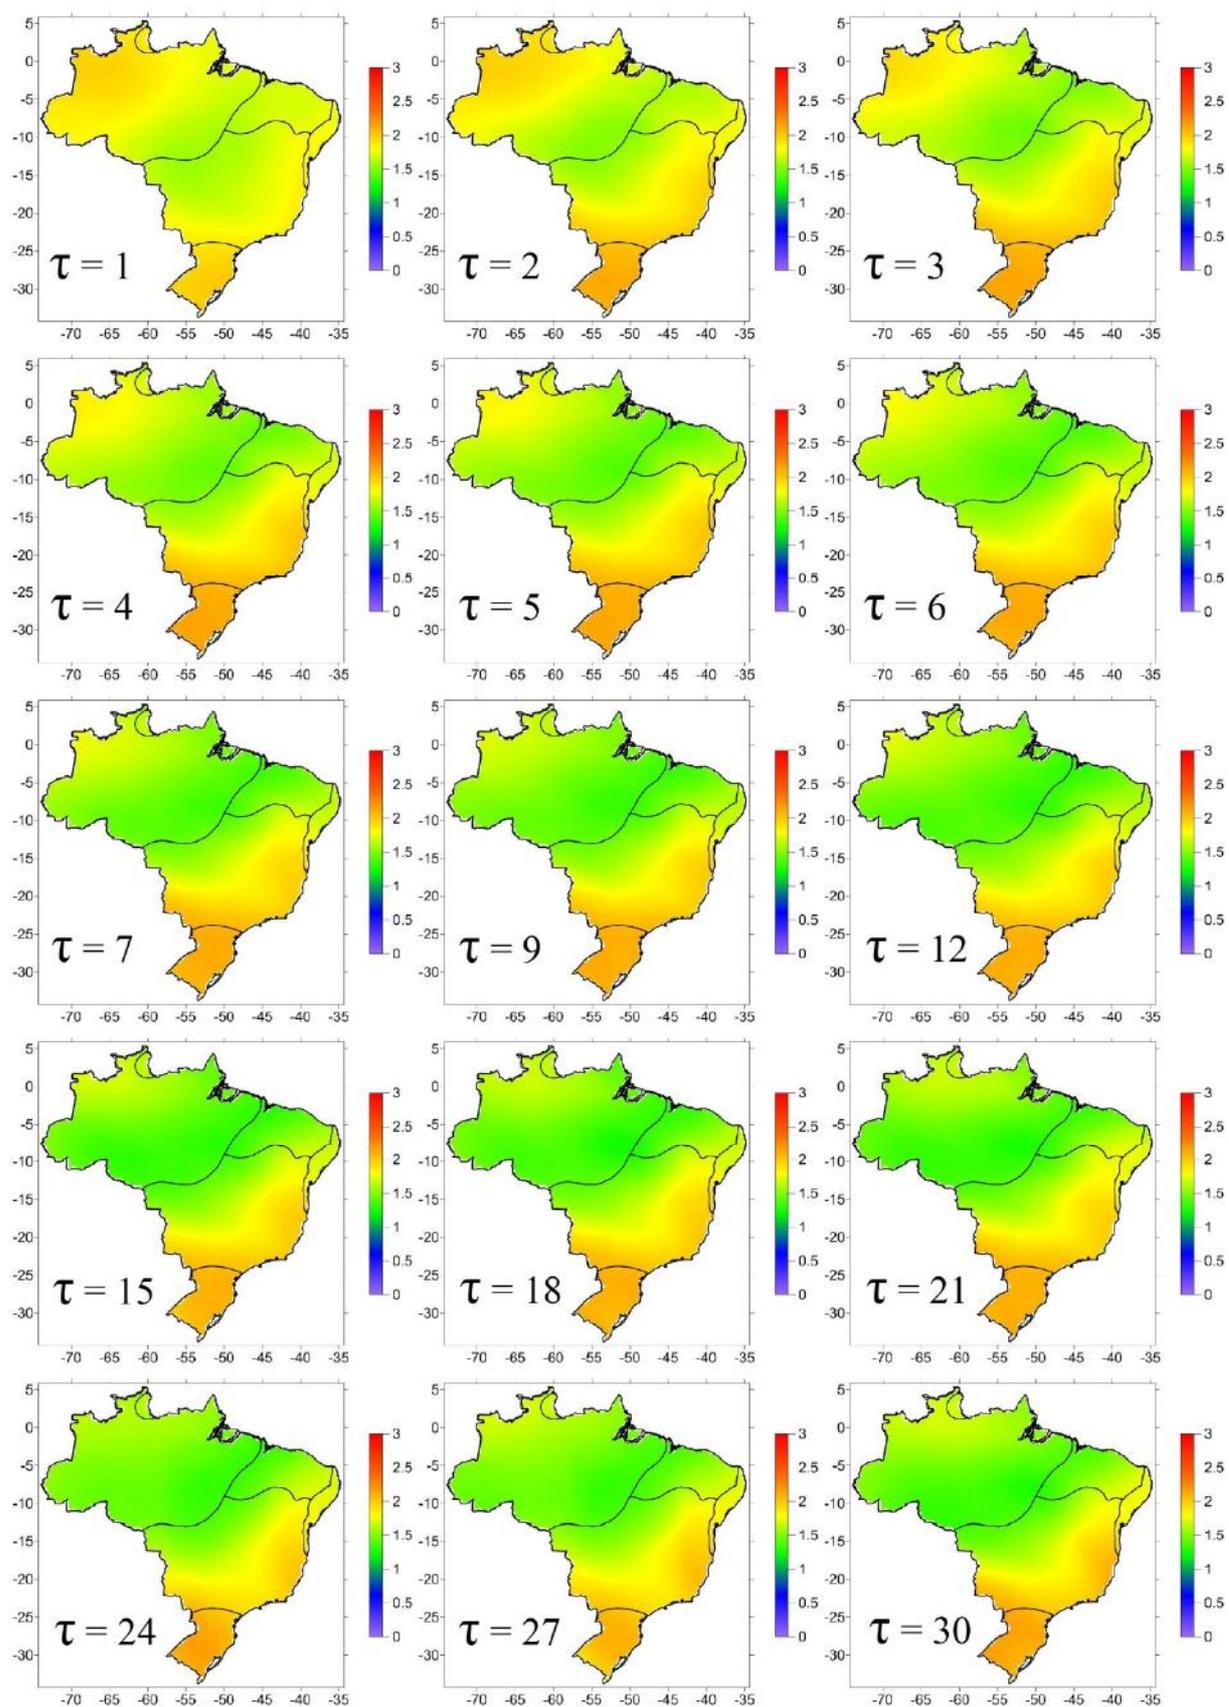
As séries de amplitude térmica diária também apresentaram regiões com autocorrelação com maiores e menores alcances (Figura 4.6 A), porém, sem seguir um padrão espacial como observado para a temperatura do ar média. Em média, no Brasil, o expoente estimado foi 0,77. Os menores valores de α foram observados no norte do Rio Grande do Sul, Santa Catarina e nos litorais do Paraná e de São Paulo, compreendendo a maior porção da região de clima Temperado. Os maiores valores de α foram observados no Pará, e em algumas áreas da região Nordeste, compreendendo as regiões de clima Tropical, Tropical Zona Equatorial e Tropical Nordeste Oriental.

Figura 4.6: Estimativas dos expoentes DFA (A) e coeficientes de *Sample Entropy* (B) das séries de amplitude térmica diária do ar do Brasil, no período de 1990 a 2012.



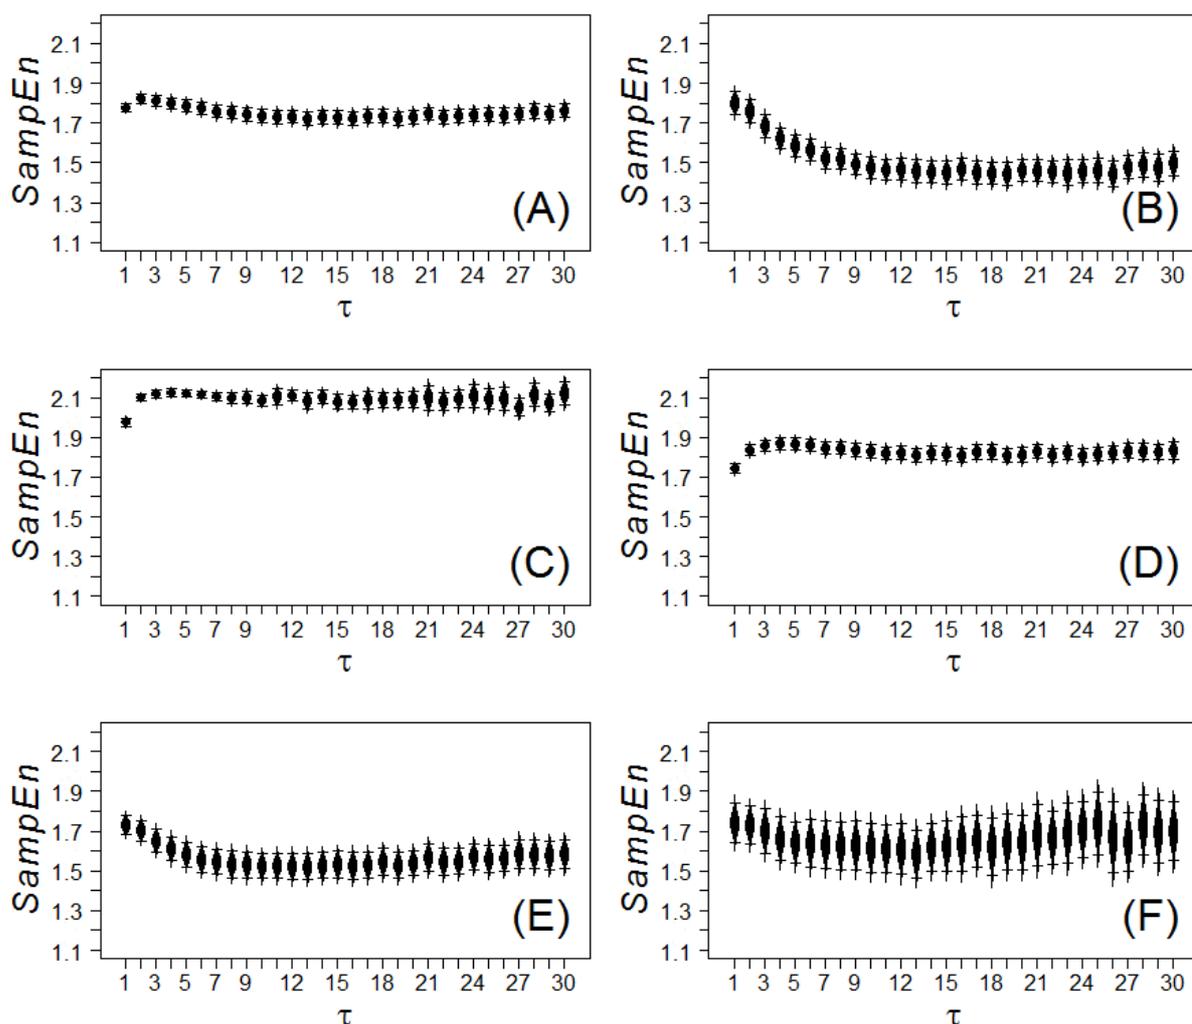
Para as séries de amplitude térmica, as entropias estimadas são observadas na (Figura 4.6 B). Na região Norte, mais precisamente nos estados de Amazonas, Acre, Rondônia e Roraima (clima Tropical), é observada uma entropia significativa, em torno de 2, para $\tau = 1$. A medida que a escala τ aumenta (Figura 4.7), esta entropia apresenta uma diminuição em sua magnitude, chegando a apresentar valores inferiores a 1 no sul do Pará, mais precisamente na região do Araguaia. As regiões Sul e Sudeste, e partes do Centro-Oeste e Nordeste, apresentaram altos valores entrópicos, onde a magnitude destes valores foi preservada com o aumento da escala τ . O aumento da escala de dias (τ) caracteriza a influência da latitude na composição da entropia, com maiores valores entrópicos em zonas mais distantes da linha do Equador.

Figura 4.7: Coeficiente de entropia (Sample Entropy) das séries de amplitude térmica diária do ar no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).



Nota-se na Figura 4.8 A, que a maior média da entropia no Brasil encontra-se na escala $\tau = 2$, sendo igual a 1,82. Esta média apresenta uma leve tendência de declínio a medida que aumenta-se a escala de dias. Notamos que as maiores entropias encontram-se na zona de clima Temperado (Figura 4.8 C), onde a média da entropia na região torna-se estável a partir de $\tau = 2$. Comportamento similar é observado na zona Tropical Brasil Central (Figura 4.8 D). Nas zonas de clima Equatorial e Tropical Nordeste oriental (Figura 4.8 B e E, respectivamente), observa-se uma nítida tendência de declínio da entropia com o aumento da escala de dias, seguida de uma posterior estabilização da mesma.

Figura 4.8: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (*Multiscale Sample Entropy*) das séries de amplitude térmica diária do ar no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).

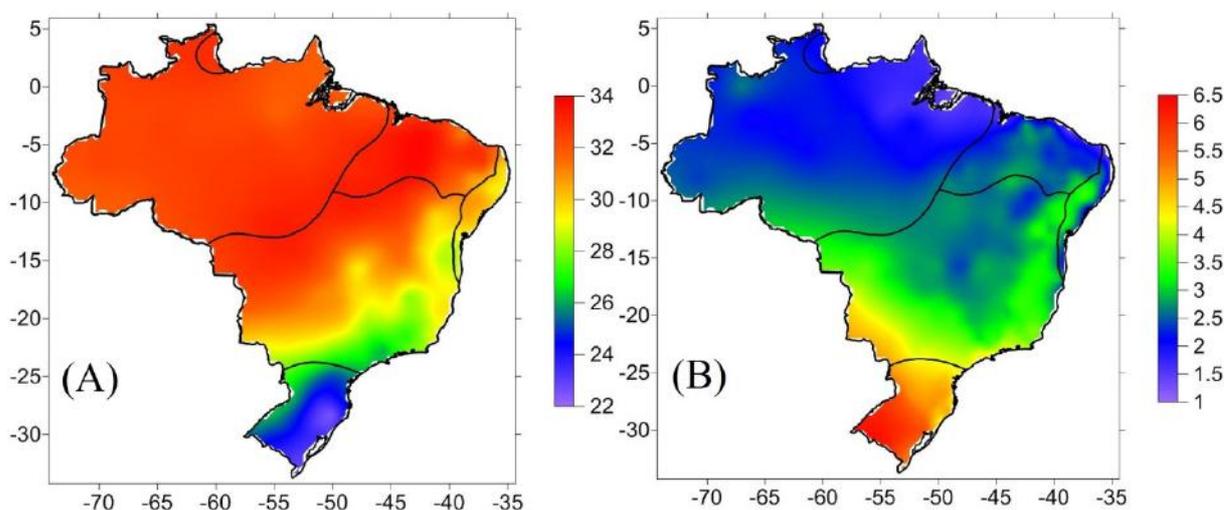


Devido a influência da continentalidade, era esperado uma menor entropia na faixa litorânea, uma vez que estudos anteriores [19] mostram que a proximidade de mares e oceanos tende a suavizar as flutuações da temperatura do ar, reduzindo a amplitude térmica local, porém, os menores valores entrópicos foram estimados em uma faixa central do país, se expandindo para o Norte e Nordeste com o aumento da escala τ . A região Sul apresentou os maiores valores de entropia, mesmo em diferentes escalas, indicando forte influência da latitude em sua composição. Em todas as escalas de dias avaliados, a região de clima Temperada foi caracterizada em todas como uma região de grande entropia. Nas regiões de clima Equatorial e Tropical Zona Equatorial esta entropia decresce com o aumento da escala de dias.

4.3 Temperatura máxima do ar

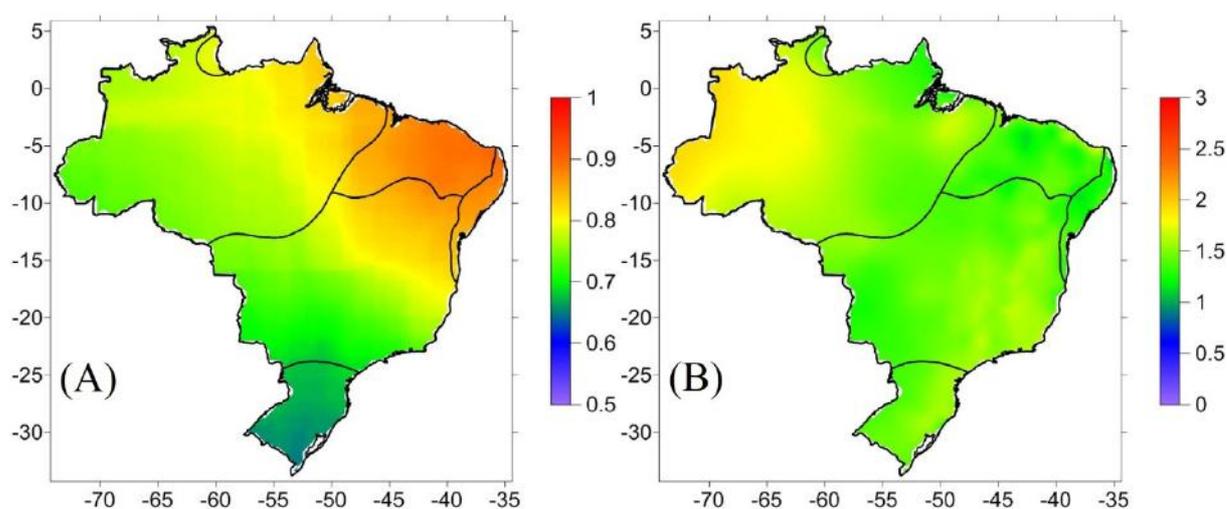
No geral, o Brasil é um país de altas temperaturas do ar, sendo que 2/3 do território do país apresentou média das temperaturas máximas diárias do ar entre 32 e 35 °C (Figura 4.9 A). A região de clima Temperado foi a que apresentou as menores médias desta variável. Assim como foi observado para a temperatura média diária do ar (Figura 4.1), as maiores variabilidades estão presentes nas regiões com menores médias (Figura 4.9 B), e vice versa. Em resumo, o distanciamento da linha do Equador atenua os registros de temperatura máxima diária do ar e aumenta a variabilidade da mesma.

Figura 4.9: Média (A) e desvio padrão (B) da temperatura máxima diária do ar no Brasil, no período de 1990 a 2012.



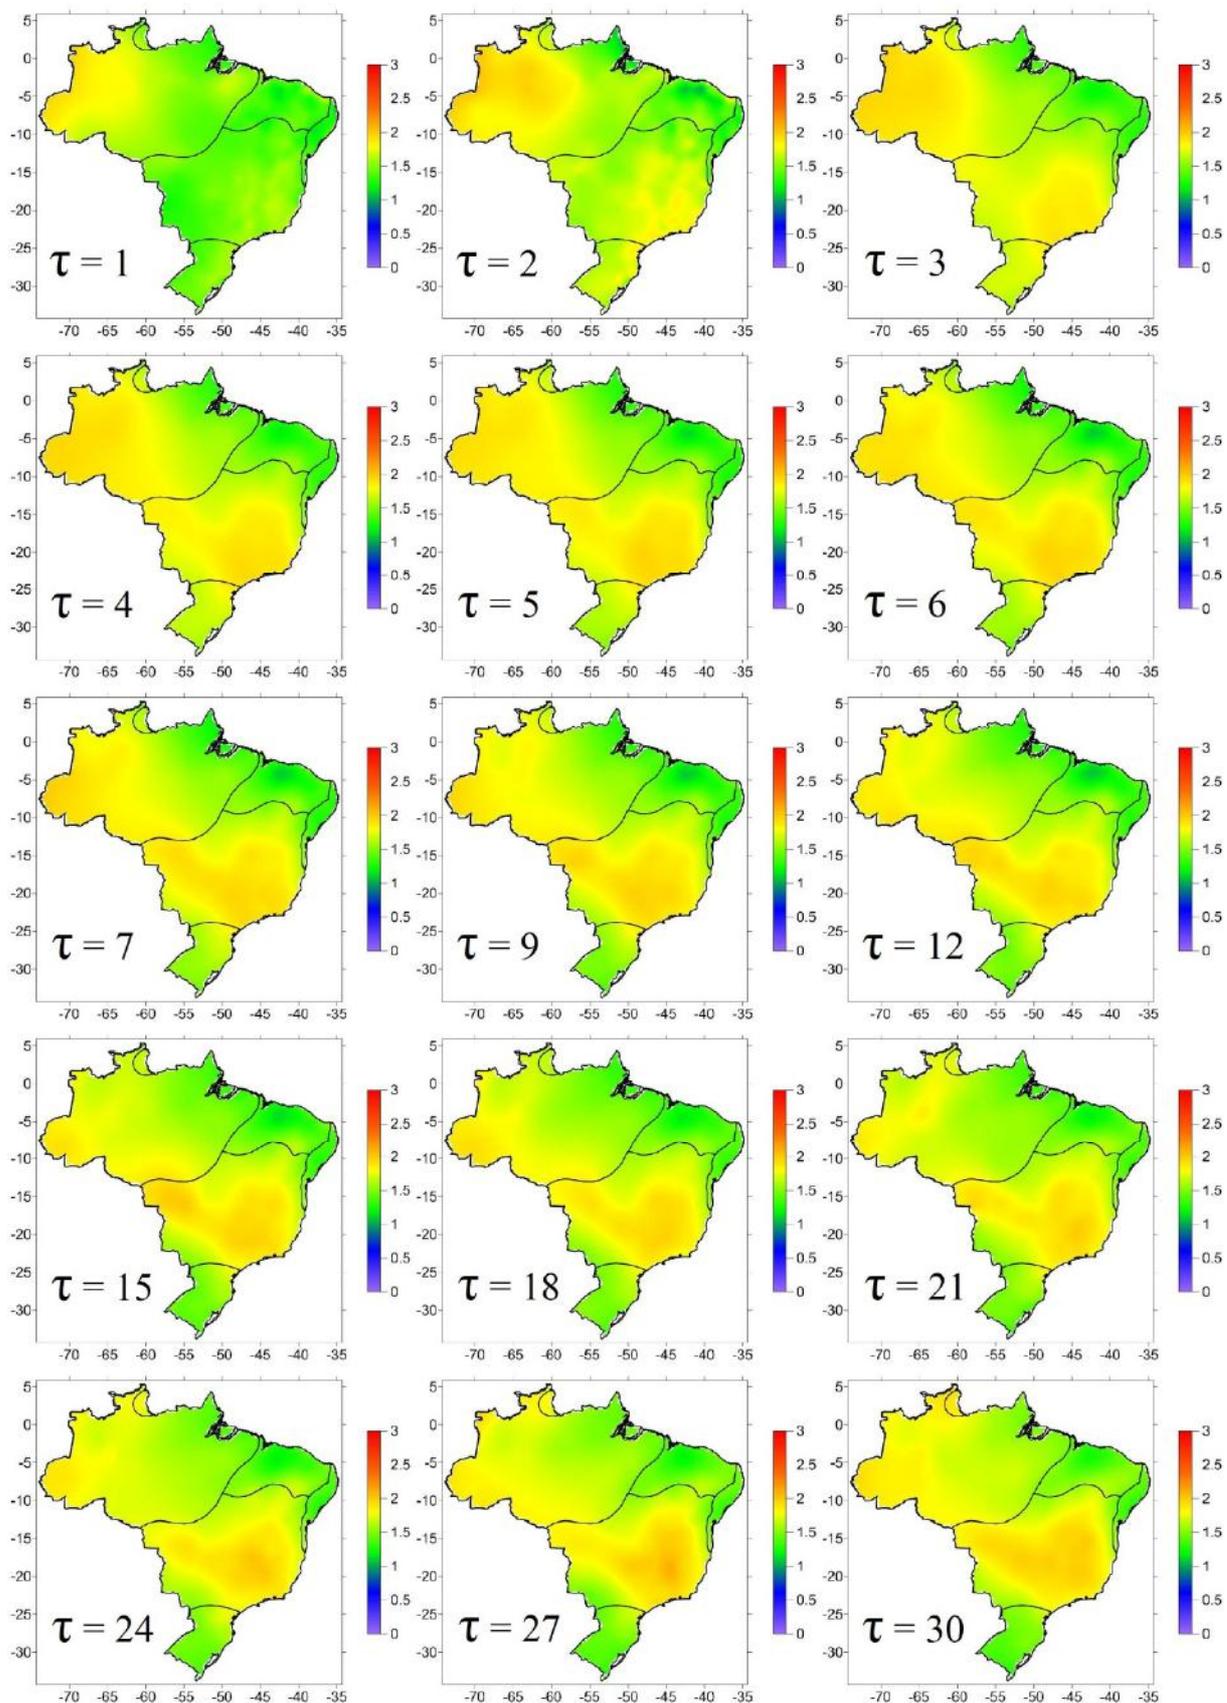
A autocorrelação observada para as séries de temperatura máxima diária do ar (Figura 4.10 A) apresentou um comportamento similar ao observado para a temperatura média diária do ar (Figura 4.2 A), com os valores do expoente de Hurst crescendo em menores latitudes e a longitude, formando faixas diagonais com diferentes limiares de α , onde os menores valores foram observados na região de clima Temperado, e os maiores no Nordeste do país, nas regiões de clima Tropical Nordeste Oriental e Tropical Zona Equatorial, sendo que a média para todo o território nacional foi de 0,79. Estas faixas diagonais seguem o mesmo sentido que as massas de ar Polar Atlântica no Inverno e Equatorial Continental no verão, conforme foi observado na Figura 2.5.

Figura 4.10: Estimativas dos expoentes DFA (A) e coeficientes de *Sample Entropy* (B) das séries de temperatura máxima diária do ar no Brasil, no período de 1990 a 2012.



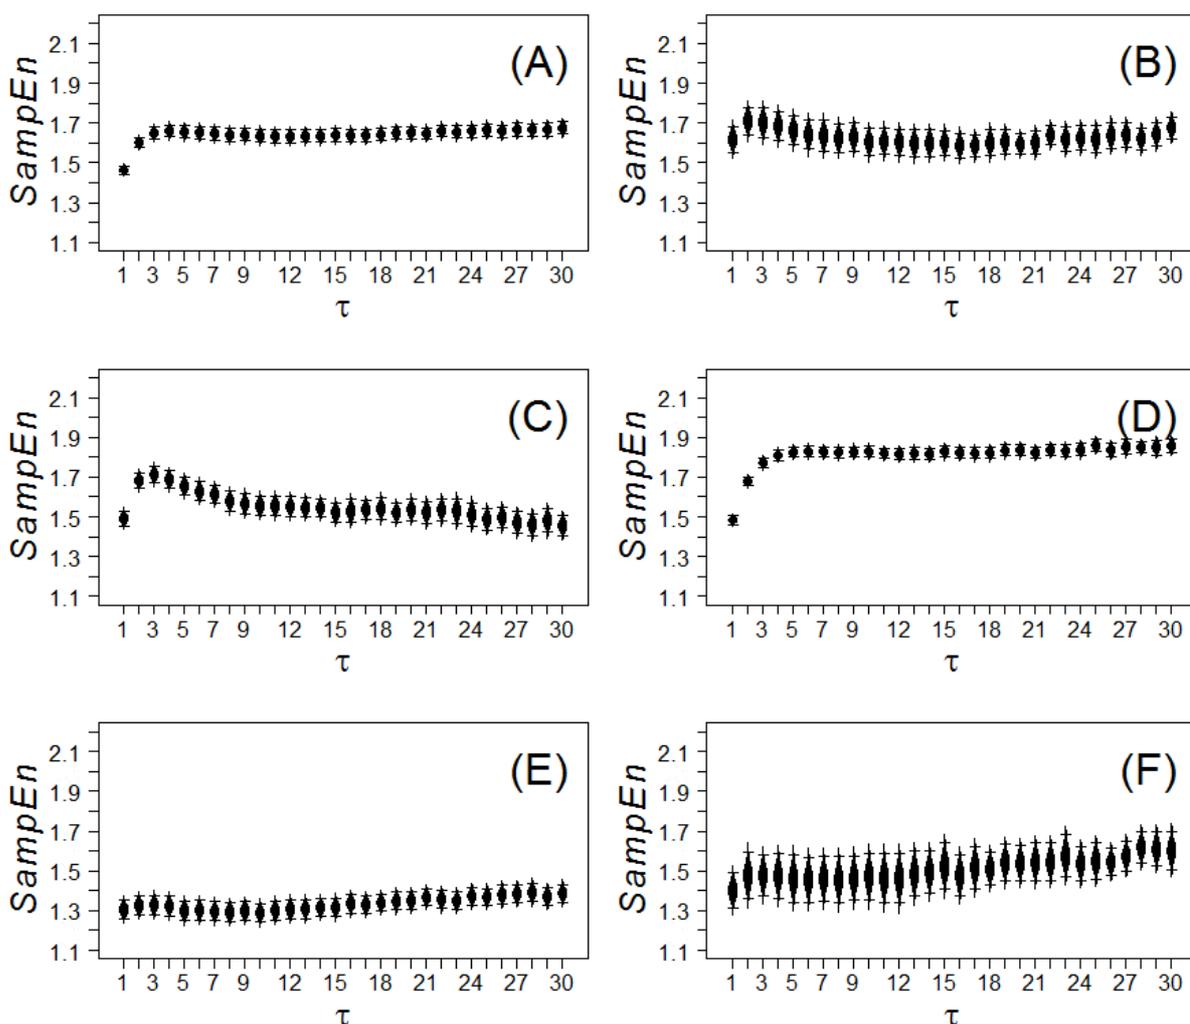
Os estados do Amazonas e do Acre (região de clima Equatorial) foram os que apresentaram menor organização (ou maior entropia) na composição das séries de temperatura máxima diária do ar (Figura 4.10 B). Observando os resultados para $\tau \geq 2$ (Figura 4.11), nota-se um aumento da entropia em grande faixa do território brasileiro, se estendendo do Amazonas até a região Sul, passando pelas regiões Centro-Oeste e Sudeste. A região Nordeste, juntamente com os estados do Pará e do Amapá apresentaram poucas mudanças no nível de entropia observado, em todas as escalas, com exceção da Bahia. Este padrão, quase constante, indica uma regular entropia, com estatísticas estimadas entre 1,0 e 1,5.

Figura 4.11: Coeficiente de entropia (Sample Entropy) das séries de temperatura máxima diária do ar no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).



A média da estatística estimada no Brasil (Figura 4.12 A) apresentou uma tendência de crescimento no intervalo $1 \leq \tau \leq 3$, seguida de uma estabilização da mesma, em torno de 1,65, para escalas acima de 4. Comportamento similar foi observado nas médias de entropia nas zonas Equatorial Tropical Brasil Central (Figura 4.12 B e D, respectivamente). As zonas Tropical Nordeste Oriental e Tropical Zona Equatorial pouco oscilaram com a variação de τ (Figura 4.12 E e F, respectivamente). A região de clima Temperado também apresentou uma tendência de crescimento no intervalo $1 \leq \tau \leq 3$, porém seguida de uma leve tendência de diminuição dos valores médios a medida que cresce a escala de dias.

Figura 4.12: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (*Multiscale Sample Entropy*) das séries de temperatura máxima diária do ar no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).



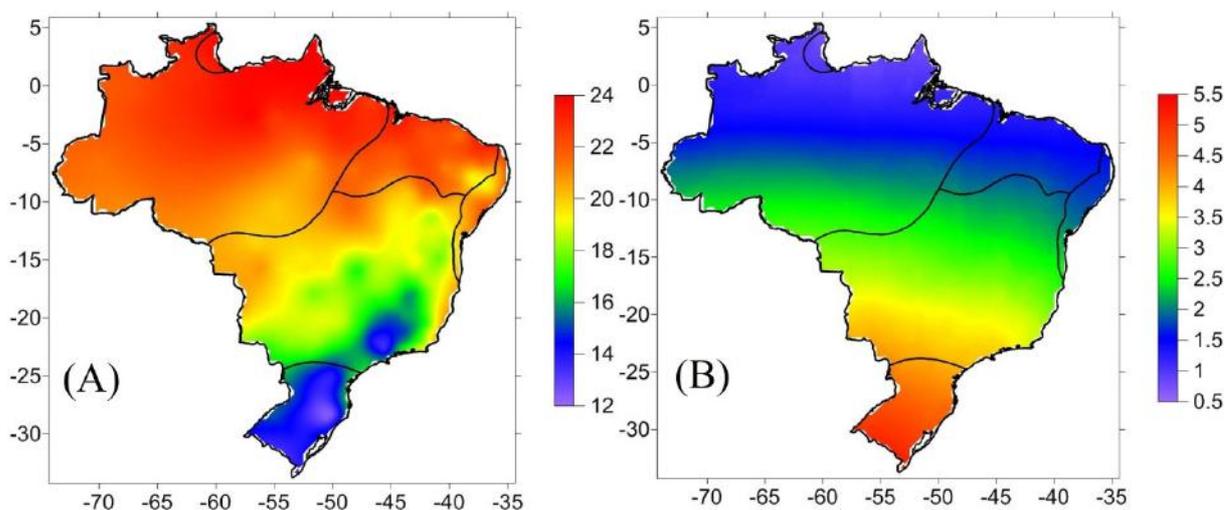
Ao compararmos nossos resultados com um estudo similar realizado na China por Zhao et al. [43], vemos que, de forma similar, não observamos correlação entre a entropia estimada com a altitude, maritimidade, latitude e vegetação. Em resumo, o aumento da escala de dias na observação da entropia mostra uma diminuição da regularidade da temperatura máxima diária nas regiões de clima Equatorial e Tropical Brasil Central, mantendo quase constante o comportamento dessa mesma estatística nas regiões de clima Tropical Zona Equatorial, Tropical Nordeste Oriental e Temperado. Esta faixa de maiores entropias observadas segue a direção da massa de ar Equatorial Continental, formada sobre a Amazônia.

4.4 Temperatura mínima do ar

A disposição espacial das médias observadas da temperatura mínima diária do ar (Figura 4.13 A) apresentou comportamento similar ao observado para a temperatura máxima diária do ar (Figura 4.9 A). A região de clima Temperado novamente é a que apresenta os menores valores. Já a região central do Brasil, em relação a temperatura mínima diária do ar, apresentou médias mais amenas, em comparação com o Norte e o Nordeste brasileiro. Esta observação ratifica o que foi visto em relação a amplitude térmica. Desta forma, podemos caracterizar a região de clima Temperado com àquela de menores médias da temperatura mínima diária do ar, a região Tropical Brasil Central com sendo a de valores mais amenos e as regiões Equatorial, Tropical Nordeste Oriental e Tropical Zona Equatorial como sendo àquelas com maiores médias observadas.

Novamente a variabilidade segue direção oposta às magnitudes das médias observadas (Figura 4.13 B). Assim como foi observado nas variáveis de temperatura média e máxima diária do ar, para a temperatura mínima diária do ar o desvio padrão observado aumenta conforme nos distanciamos da linha do Equador. Observam-se faixas bem definidas no limiar do desvio padrão observado, caracterizando a influência da latitude em sua composição. Em resumo, a proximidade da linha do Equador resulta em temperaturas altas e constantes.

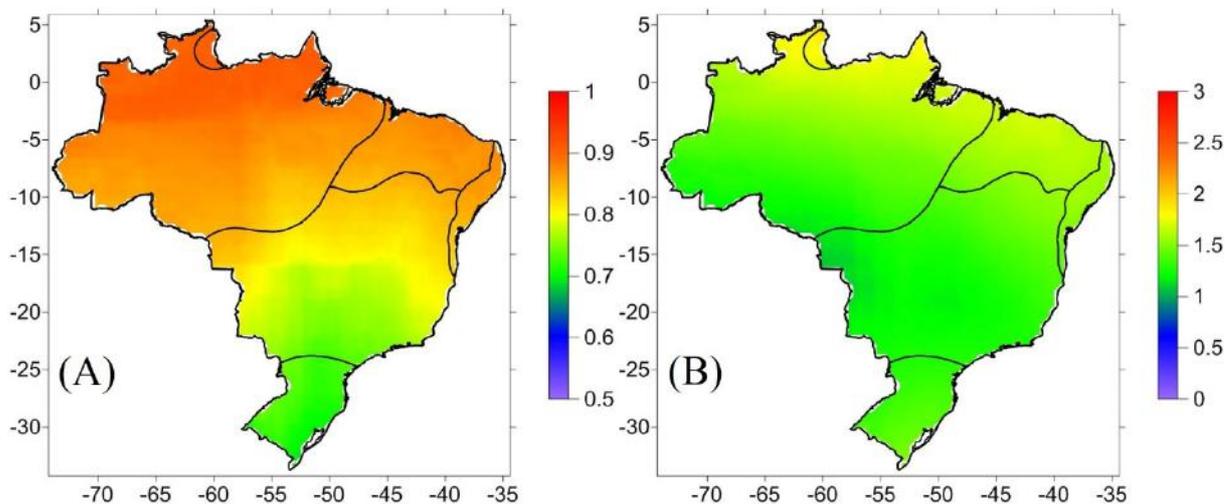
Figura 4.13: Média (A) e desvio padrão (B) da temperatura mínima diária do ar no Brasil, no período de 1990 a 2012.



Para as temperaturas mínimas diárias do ar, observou-se que os valores estimados de α (Figura 4.14 A) crescem na direção das menores latitudes, sendo as séries com autocorrelação de maior alcance localizadas no extremo norte do país, e àqueles com menor memória, no extremo sul. Para esta variável os menores valores de α observados giraram em torno de 0,7, diferente das demais variáveis de temperatura do ar (média, máxima e amplitude), que apresentaram valores de α em torno de 0,6 na região de clima Temperado. Observamos na Figura 4.14 B as entropias estimadas para temperatura mínima do ar. Para $\tau = 1$ observa-se um mapa bastante homogêneo, com entropias entre 1,0 e 1,5, com uma sutil diminuição dos valores da entropia com o aumento da latitude. Ou seja, tanto o alcance da autocorrelação, quando a entropia da série de temperatura mínima diária do ar aumentam com uma maior proximidade da linha do Equador.

Ao contrário dos estudos de Fraedrich e Blender [68] e de Eichner et al. [76], não observamos uma forte relação da maritimidade com as estimativas de α nas variáveis de temperatura do ar (média, máxima, mínima e amplitude térmica) estudadas. A magnitude dos expoentes apresentou maior relação com a posição geográfica (latitude e longitude) do que com a proximidade com o Oceano Atlântico. Resultados similares foram apresentados por Király e János [77], em um estudo realizado na Austrália.

Figura 4.14: Estimativas dos expoentes DFA (A) e coeficientes de *Sample Entropy* (B) das séries de temperatura mínima diária do ar no Brasil, no período de 1990 a 2012.



Este comportamento observado nas estimativas de *SampEn* (Figura 4.14 B) torna-se completamente diferente quando $\tau > 1$ (Figura 4.15). Em Mato Grosso e no sul do Pará é observada uma entropia próxima de zero, indicando certa regularidade da temperatura mínima do ar. Esta área apresenta-se pequena para $\tau = 2$, aumenta até $\tau = 13$, e após, diminui gradativamente. As maiores entropias estão localizadas nas áreas de maior latitude, sendo que esta área diminui com o aumento de τ . Em geral não se nota diferença na disposição da entropia no Brasil a partir de $\tau > 1$, o comportamento observado reflete apenas o aumento ou diminuição das áreas caracterizadas. E não há uma caracterização clara da influência das zonas climáticas nessa caracterização.

Ao analisarmos as médias (Figura 4.16 A), observamos que o maior valor entrópico médio (1,82) foi observado em $\tau = 2$. As médias das estimativas seguem uma leve tendência de decaimento até a escala $\tau = 12$, sendo 1,63 o menor entropia observada. A partir de $\tau = 15$ os valores médios passam a apresentar uma suave tendência de crescimento com o aumento da escala, onde a tendência de decaimento é mais acentuada do que a de crescimento. Tal comportamento mostrou-se similar nas zonas climáticas Equatorial, Tropical Brasil Central, Tropical Nordeste Oriental e Tropical Zona Equatorial (Figura 4.16 B, D, E e F, respectivamente). Apenas as médias entrópicas na zona Temperada destoou das demais zonas, apresentando um aumento na entropia no intervalo $1 \leq \tau \leq 3$, seguida de uma suave diminuição da entropia na região.

Figura 4.15: Coeficiente de entropia (Sample Entropy) das séries de temperatura mínima diária do ar no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias)..

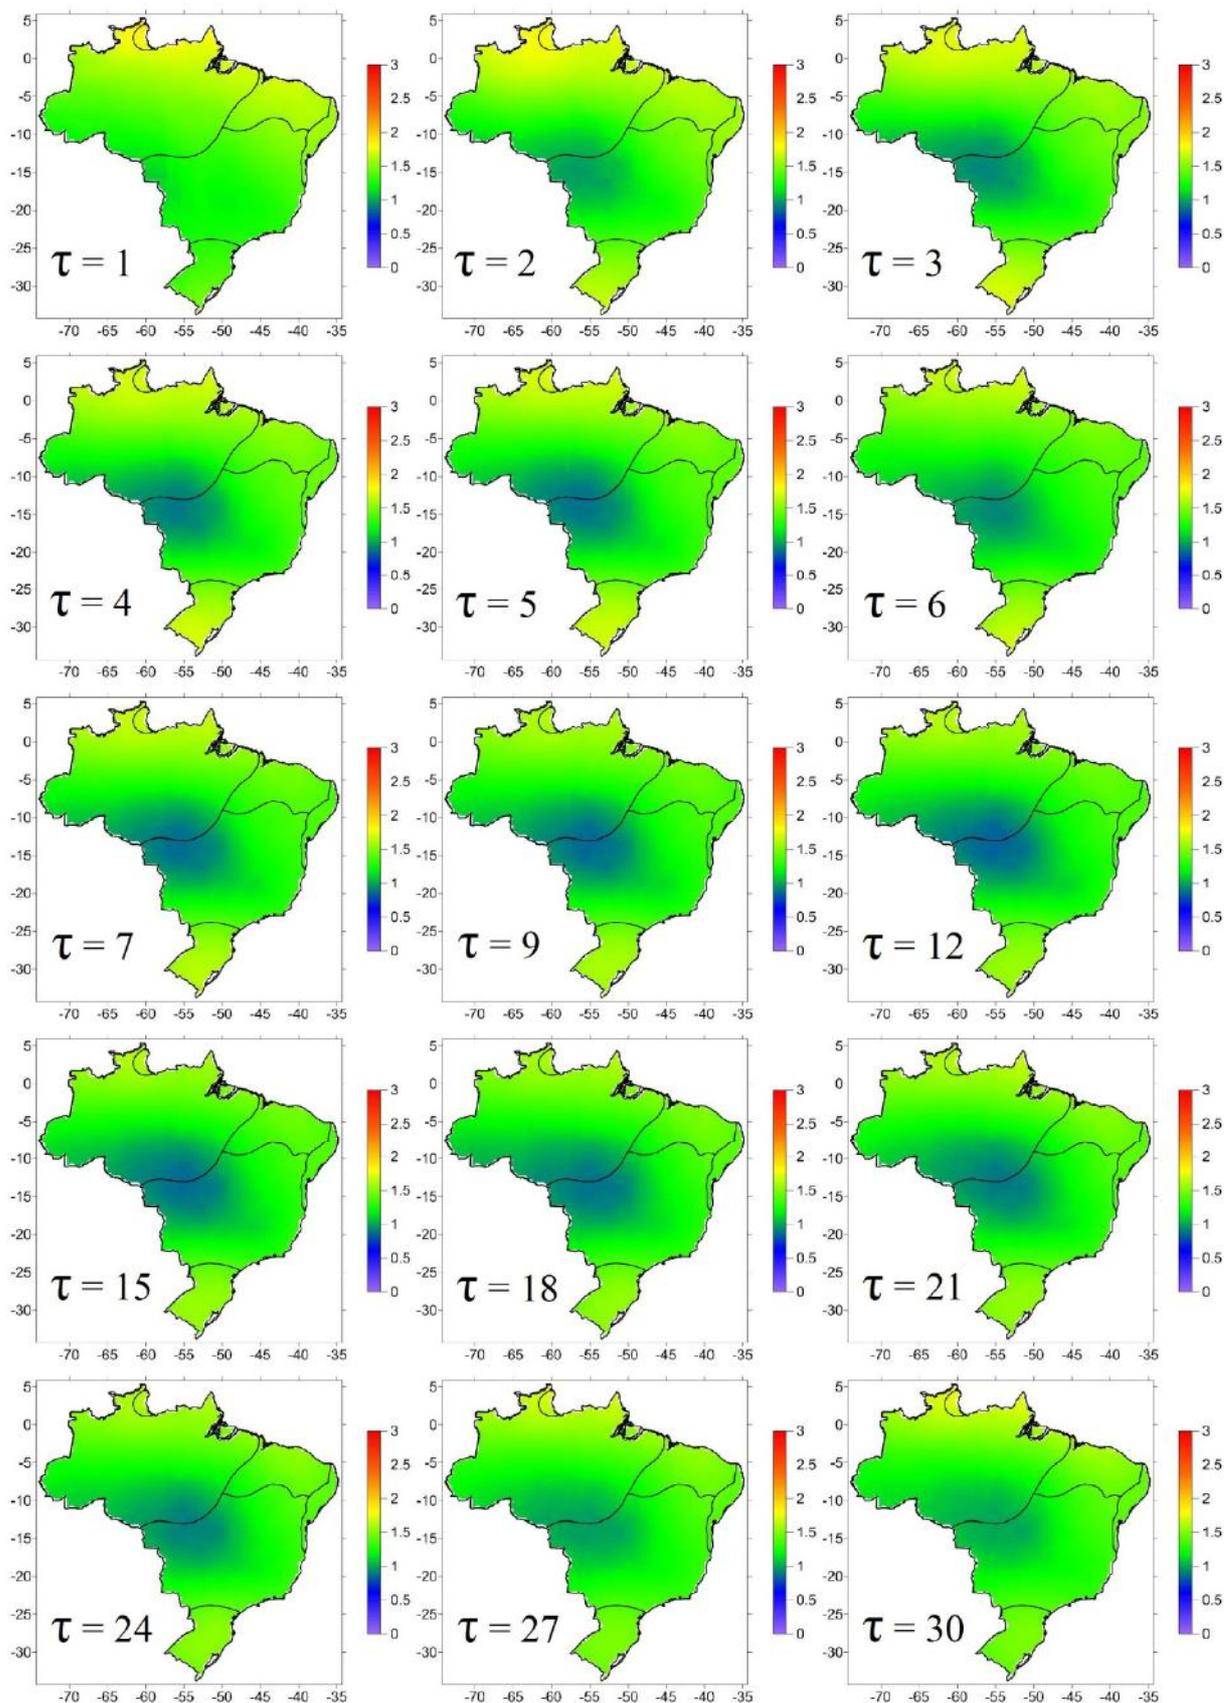
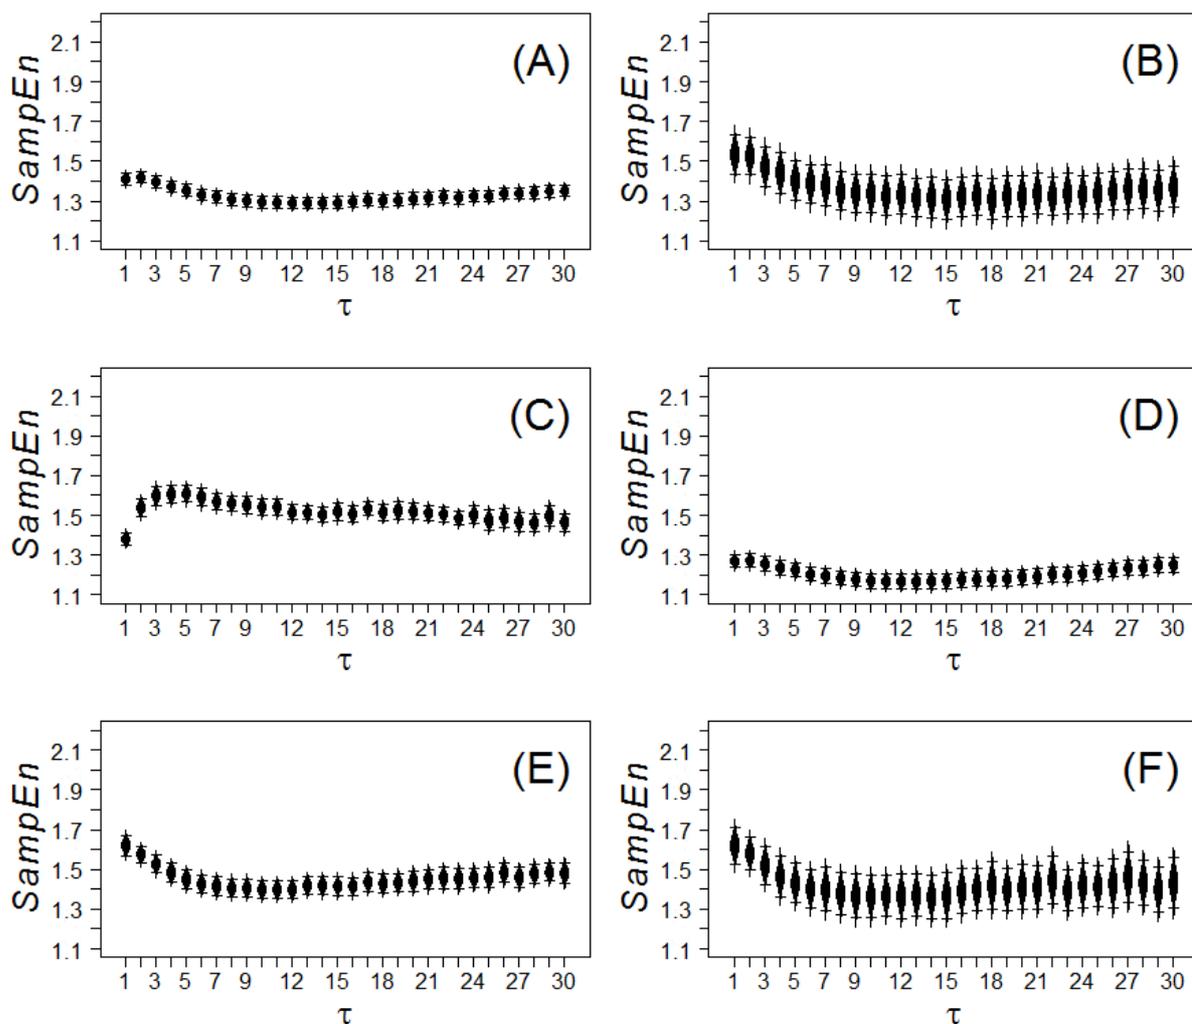


Figura 4.16: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (*Multiscale Sample Entropy*) das séries de temperatura mínima diária do ar no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).



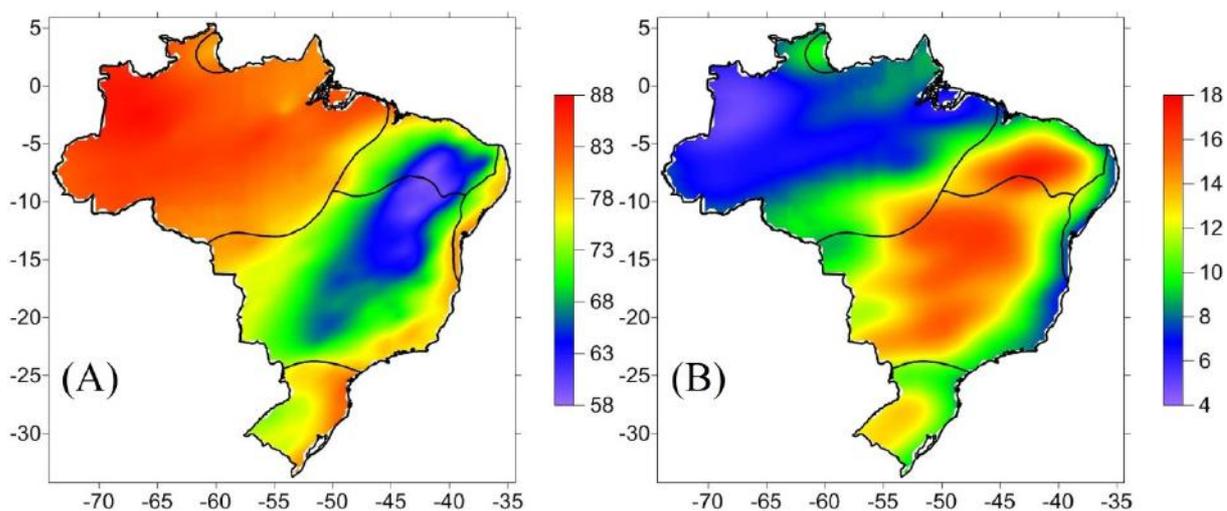
4.5 Umidade relativa média do ar

As regiões mais distantes de grandes massas de água foram as que apresentaram menores valores médios de umidade relativa média diária do ar (Figura 4.17 A), conforme já esperado. As exceções foram as bacias dos rios São Francisco e Parnaíba, que mostraram não alterar a dinâmica de baixa umidade relativa média diária do ar no sertão nordestino. Destacamos a região Amazônica (clima Equatorial), local onde foram observadas as maiores médias de umidade relativa média diária do ar. A combinação de grandes volumes de água (bacia Amazônica), altas tem-

peraturas do ar, vegetação densa, e baixas velocidades do vento (evitando a dispersão da umidade do ar), contribuíram para fazer desta, a região com maior umidade relativa média diária do ar média do país. Esta alta umidade sob a região de clima Equatorial é uma característica absorvida pela massa de ar Equatorial Continental, que atua ao longo do ano sobre as regiões de clima Tropical Brasil Central e Temperado.

As menores variabilidades da umidade relativa média diária do ar foram observadas em regiões próximas a grandes volumes de água, a região Amazônica e o litoral do Brasil, conforme Figura 4.17 B. As maiores variabilidades foram observadas nas regiões que apresentaram as menores médias de umidade relativa do ar. Em outras palavras, a proximidade de grandes volumes de água cria nessas regiões um ambiente homogêneo, com elevados registros de umidade relativa do ar e uma baixa variabilidade ao longo dos dias.

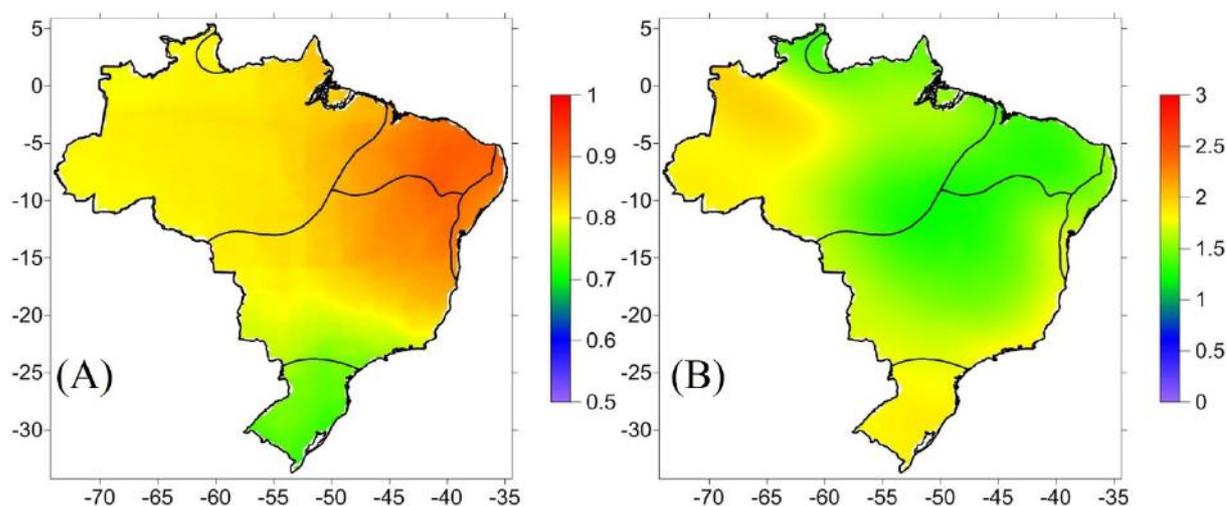
Figura 4.17: Média (A) e desvio padrão (B) da umidade relativa média diária do ar no Brasil, no período de 1990 a 2012.



A umidade relativa média diária do ar apresentou os maiores valores de α na região de clima Tropical Nordeste Oriental e Tropical Zona Equatorial, e em uma porção da região de clima Tropical Brasil Central (Figura 4.18 A), e novamente os menores valores foram observados na região de clima Temperado. A maior proximidade (ou distância) de grandes massas de água não mostrou ter uma correlação com as estimativas do DFA, tão pouco observa-se relação com a temperatura do ar, latitude e longitude. Na China, Chen et al. [71] observaram uma relação entre o valor

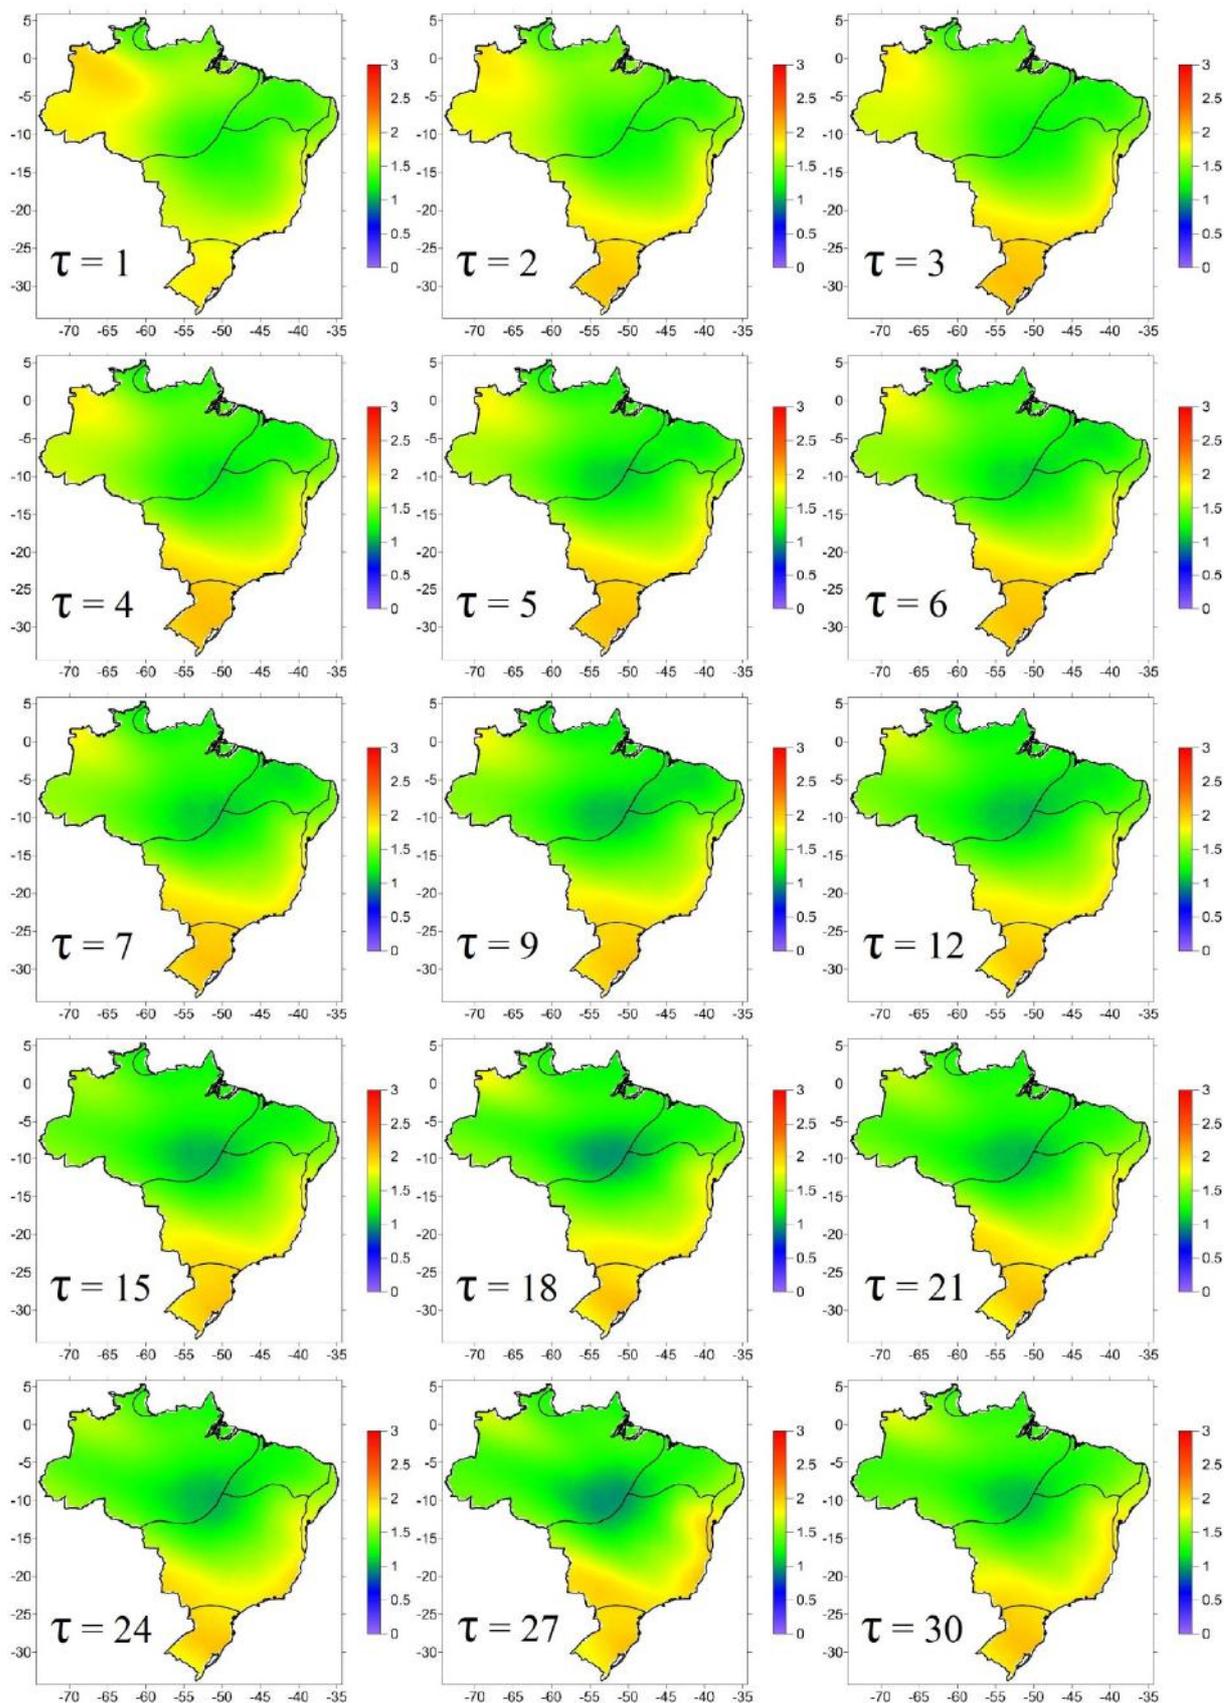
de α , para séries de umidade relativa média diária do ar, com as diferentes regiões climáticas do país. Em nossos resultados podemos classificar as regiões Tropical Zona Equatorial e Tropical Nordeste Oriental como àquelas com maior alcance da autocorrelação observada na série de umidade relativa média diária do ar, a zona Temperada com a de menor alcance da autocorrelação e a Equatorial com um α intermediário entre estes grupos. Já a região Topical Brasil Central reúne características da autocorrelação observada nas nas demais zonas climáticas.

Figura 4.18: Estimativas dos expoentes DFA (A) e coeficientes de *Sample Entropy* (B) das séries de umidade relativa média diária do ar do Brasil, no período de 1990 a 2012.



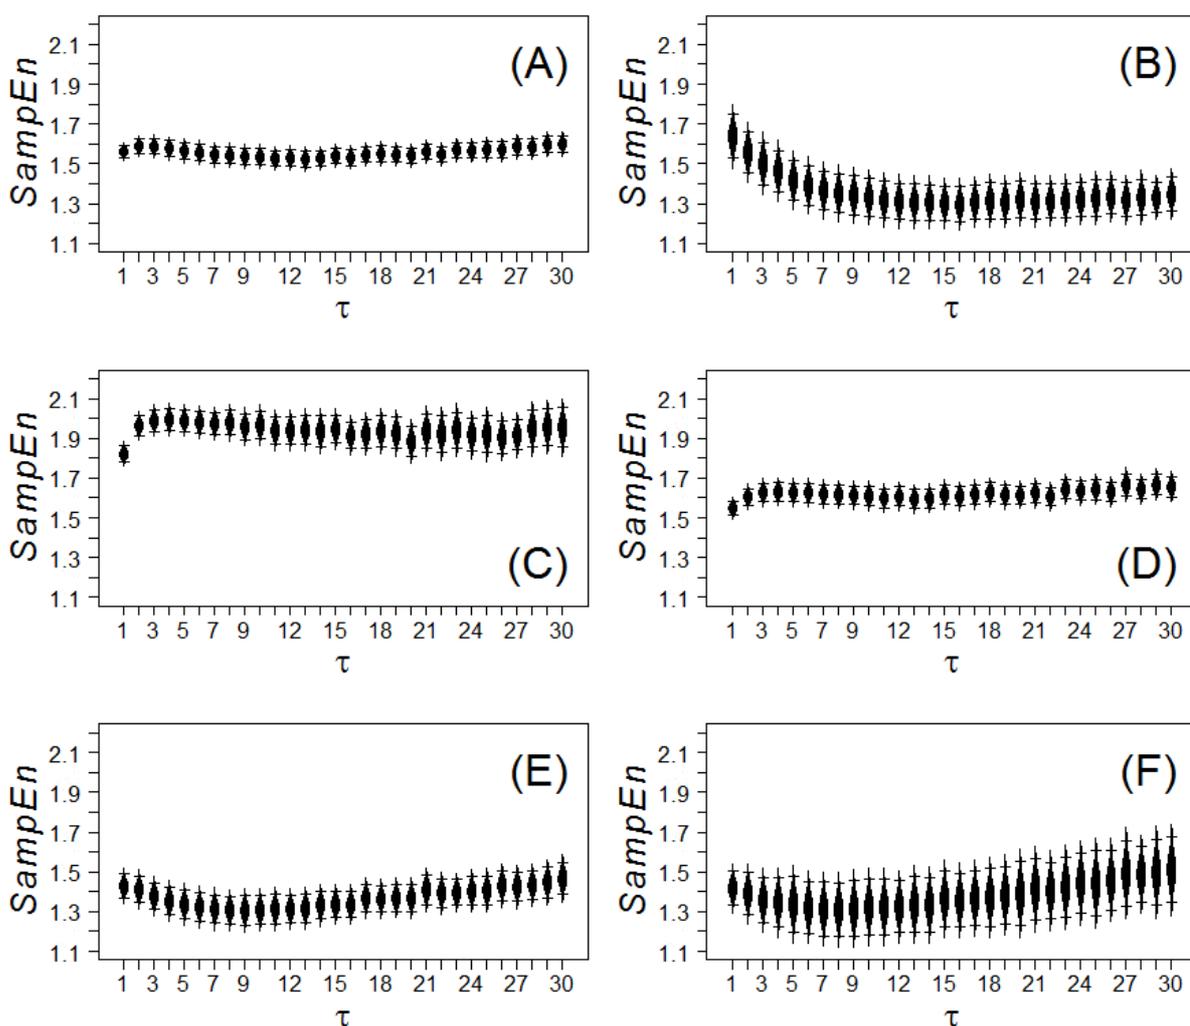
Em relação às estimativas da entropia nas séries de umidade relativa média diária do ar (Figura 4.18 B), nota-se que quando $\tau = 1$, a variação da entropia é mais homogênea, girando em torno de 1,5, com os menores valores sendo observados em uma faixa que corta do Centro-Oeste ao Nordeste, incluindo alguns estados das regiões Norte e Sudeste. A partir da escala $\tau = 2$ (Figura 4.19), esta variabilidade aumenta, onde se observa o crescimento da entropia na região de clima Temperado, e em uma porção da região de clima Tropical Brasil Central (estados do Rio Grande do Sul, Santa Catarina, Paraná, Mato Grosso do Sul, São Paulo, Rio de Janeiro, Espírito Santo e em um trecho da Bahia). Este comportamento também é observado no norte do Amazonas. As menores entropias foram detectadas bem no centro do país, em uma região que interceptam os climas Equatorial, Tropical Brasil Central e Tropical Zona Equatorial.

Figura 4.19: Coeficiente de entropia (Sample Entropy) das séries de umidade relativa média diária do ar no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).



O valor médio estimado da entropia no Brasil para $\tau = 1$ foi de 1,56 (Figura 4.20 A). Esta estatística chega a 1,59, quando $\tau = 2$, decaindo até 1,52, quando $\tau = 13$. A partir deste ponto as estimativas de *SampEn* voltam a crescer, chegando a 1,60 na escala $\tau = 30$. Observa-se comportamento semelhante nas zonas de clima Temperado e Tropical Brasil Central (Figura 4.20 C e D, respectivamente). Na zona Equatorial (Figura 4.20 B) notam-se valores maiores de entropia quando $\tau = 1$, com o decaimento da estatística, seguida de uma estabilização da mesma. Nas zonas de clima Tropical Nordeste Oriental e Tropical Zona Equatorial (Figura 4.20 E e F, respectivamente), nota-se uma leve concavidade na sequência dos valores médios.

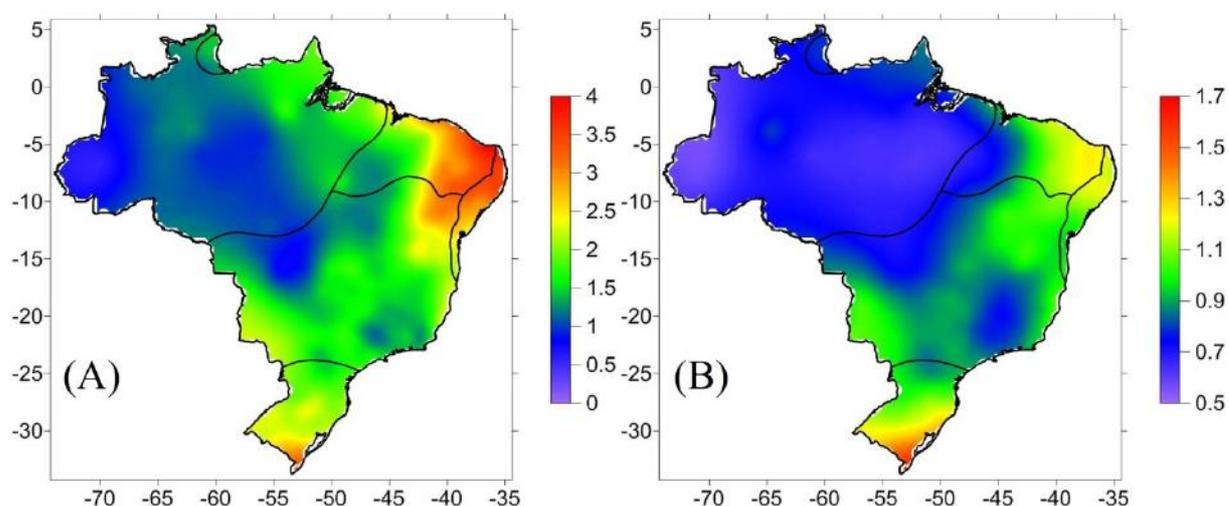
Figura 4.20: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (*Multiscale Sample Entropy*) das séries de umidade relativa média diária do ar no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).



4.6 Velocidade média do vento

No geral, o Brasil é um país com baixas médias de velocidade média diárias do vento (Figura 4.21 A). A maior parte do território brasileiro apresentou velocidades médias diárias entre 0 e 1 m/s , classificado entre calmo e leve, segundo a classificação de Beaufort [2]. O Nordeste (na região de clima Tropical Nordeste Oriental e em uma porção da região Tropical Zona Equatorial) apresentou as maiores médias desta variável, chegando a apresentar velocidades médias diárias de 5 m/s (brisa suave). Esta região é considerada a de maior potencial eólico no país [2]. As menores médias da velocidade da média diária do vento foram observadas sob a zona de clima Equatorial. Especialmente, a distribuição da média e desvio padrão (Figura 4.21 B) da velocidade média diária do vento assemelham-se, onde os registros de menor variabilidade coincidem com aqueles de menores médias.

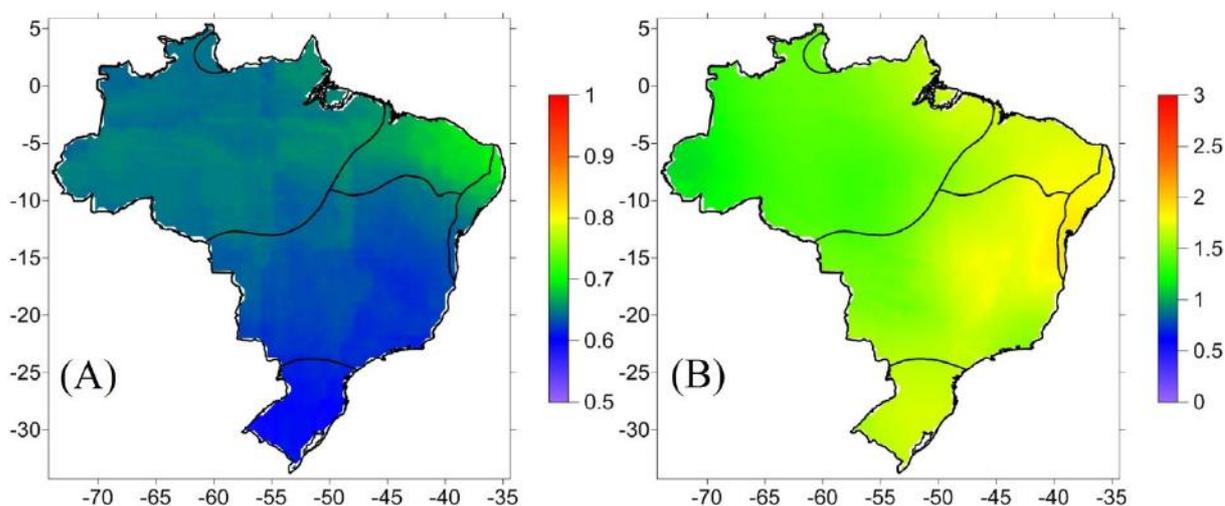
Figura 4.21: Média (A) e desvio padrão (B) da velocidade média diária do vento no Brasil, no período de 1990 a 2012.



A velocidade média diária do vento, conforme se observa na Figura 4.22 A, apresentou na maior parte do território nacional autocorrelações de curto alcance (média de 0,64), sob todo o território brasileiro, aproximando-se do limiar que caracteriza a série como aleatória. Os maiores valores de α foram observados na região Nordeste do Brasil, sob as zonas Tropical Zona Equatorial e Tropical Nordeste Oriental. Assim como no estudo de Santos et al. [14], não observamos correlação entre o expoente α e fatores climáticos (latitude, longitude, altitude e continentalidade) pa-

ra a velocidade média diária do vento, porém suas estimativas indicaram um longo alcance desta autocorrelação, com estimativas próximas de 1, em quatro estações meteorológicas do estado de Pernambuco, enquanto que nossas estimativas encontram-se em torno de 0,7 para este mesmo estado. A diferença na escala temporal da variável em estudo pode ter gerado esta diferença, uma vez que Santos et al. [14] utilizaram séries horárias de velocidade do vento em seu trabalho, enquanto que neste trabalhos utilizamos séries diárias.

Figura 4.22: Estimativas dos expoentes DFA (A) e coeficientes de *Sample Entropy* (B) das séries de velocidade média diária do vento no Brasil, no período de 1990 a 2012.



A estimativa de *SampEn* para a velocidade média diária do vento apresentou padrão espacial bastante regular (Figura 4.22 B), com os maiores valores de entropia observados na região Nordeste, predominantemente na zona de clima Tropical Nordeste Oriental. Com o aumento da escala $\tau \geq 2$ os valores da entropia nessa região diminuem (Figura 4.23). As médias das estatísticas estimadas no Brasil (Figura 4.24 A) apontam um crescimento inicial (de 1,66 quando $\tau = 1$ até 1,75 quando $\tau = 3$), seguida de uma tendência de decréscimo da entropia, se estabilizando em torno de 1,60, quando $\tau = 18$. Este comportamento também é observado nas zonas de clima Equatorial, Temperado e Tropical Brasil Central (Figura 4.24 B, C e D, respectivamente). Já as zonas de clima Tropical nordeste Oriental e Tropical Zona Equatorial (Figura 4.24 E, F, respectivamente), apresentaram maiores valores entrópicos na escala $\tau = 1$, seguida de uma leve tendência de decréscimo da estatística com o aumento de τ .

Figura 4.23: Coeficiente de entropia (Sample Entropy) das séries de velocidade média diária do vento no Brasil, no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).

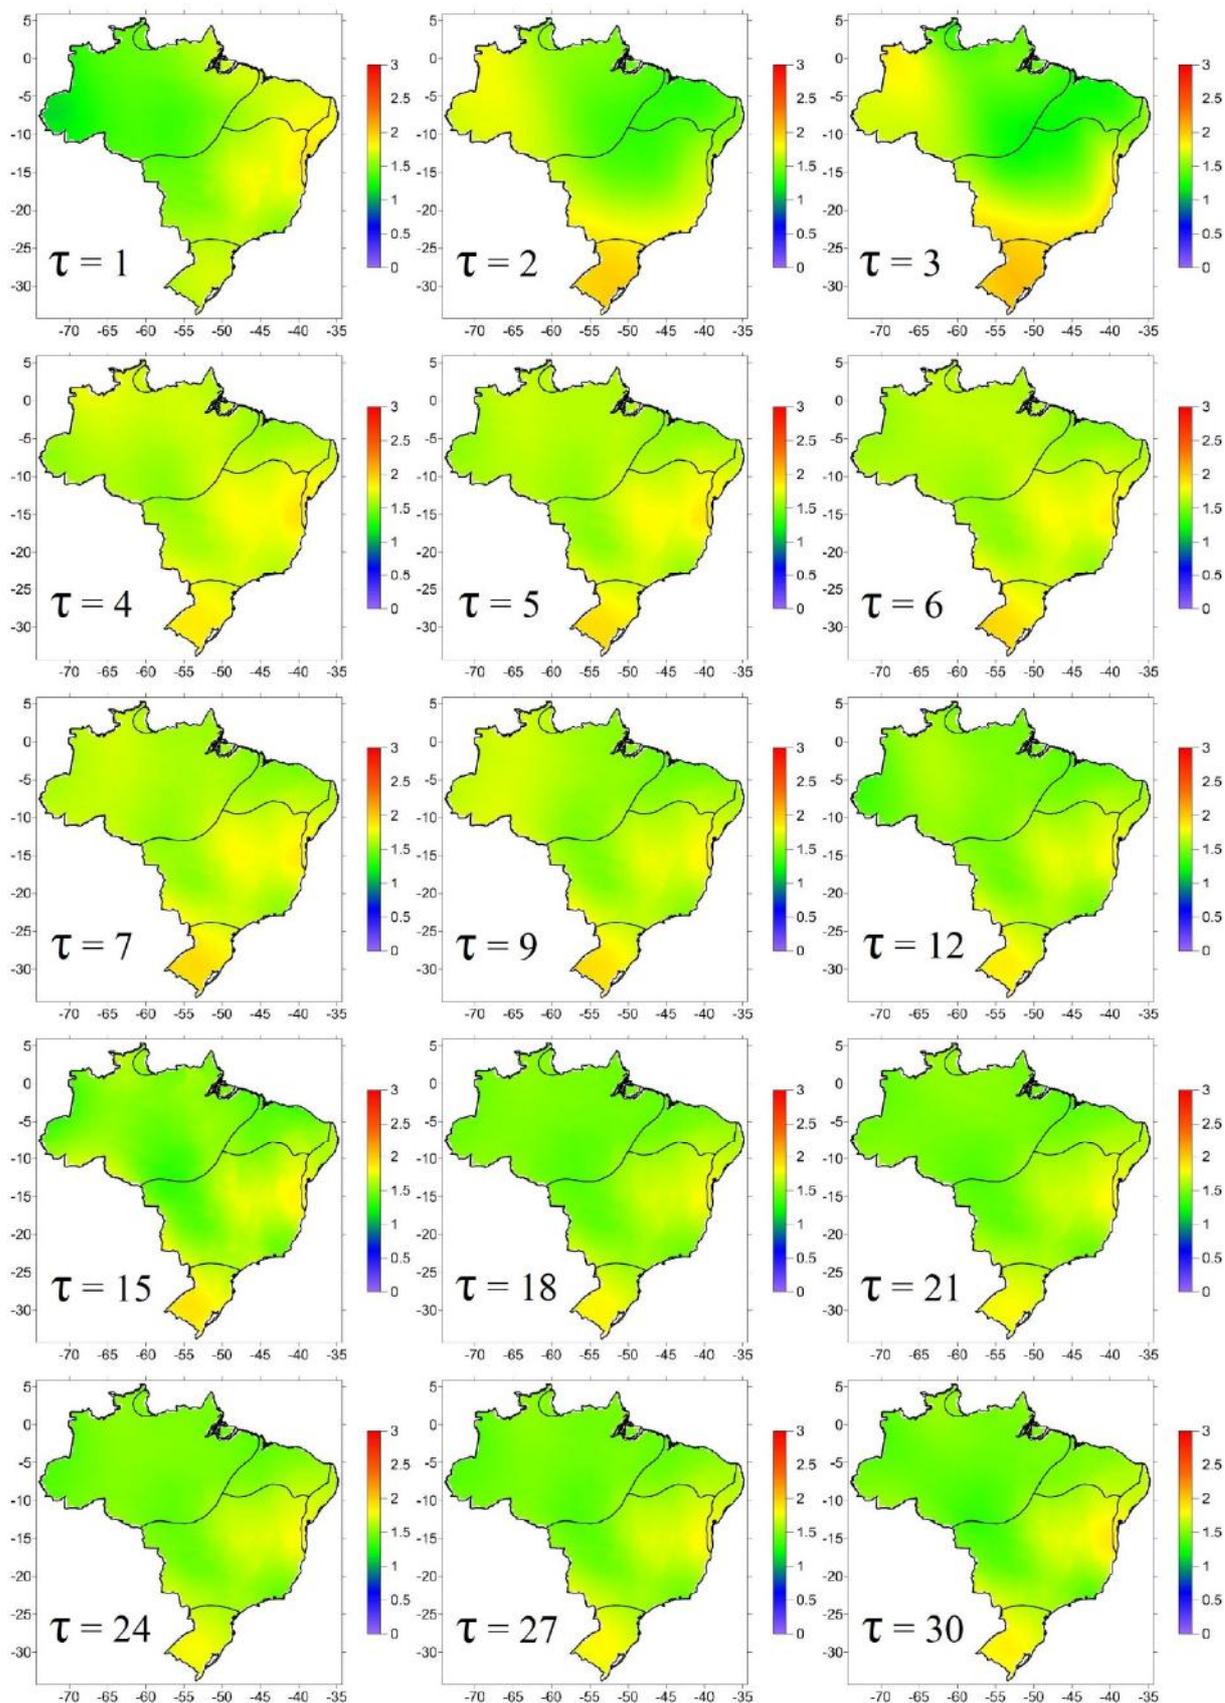
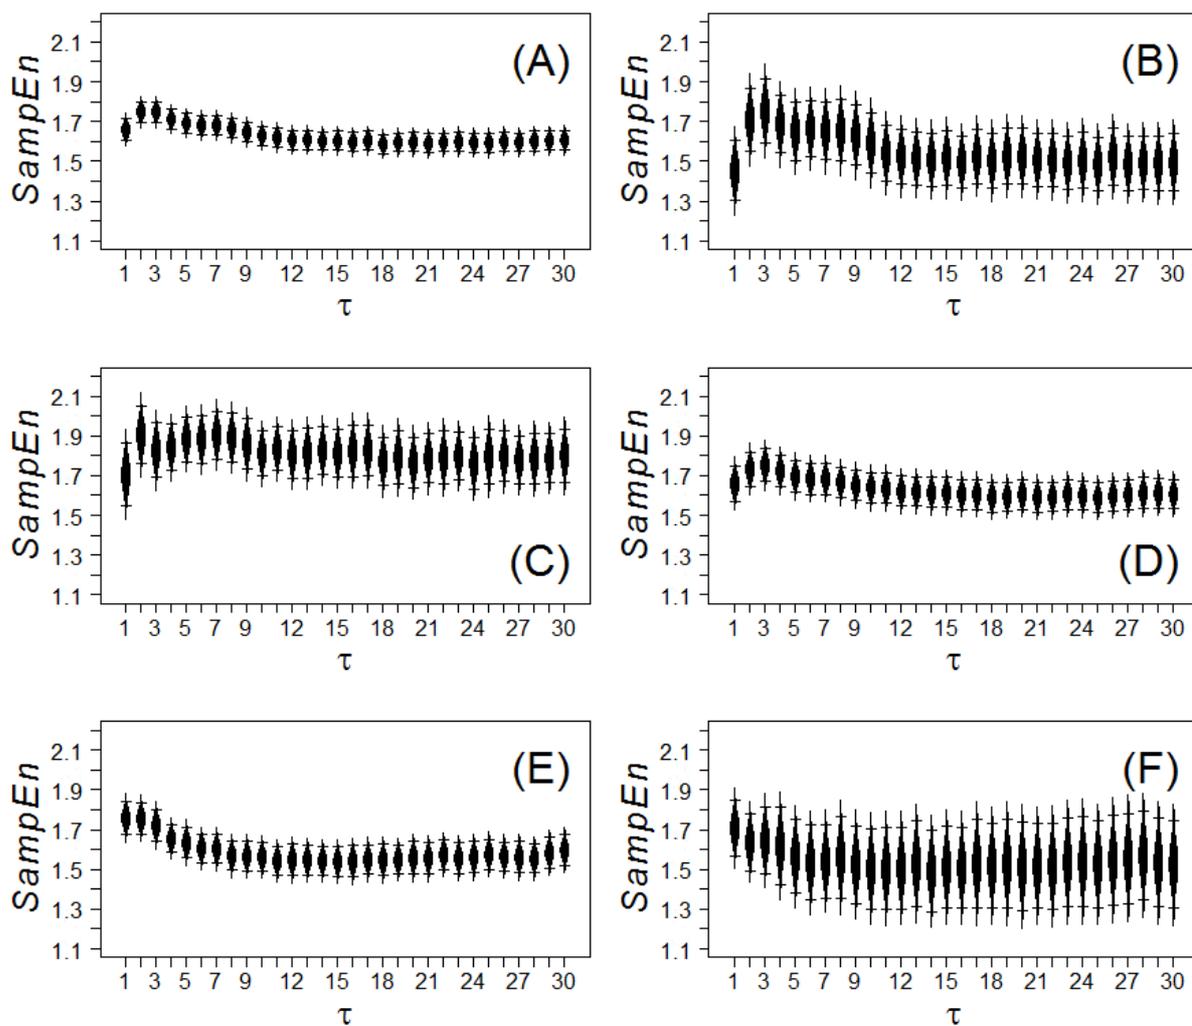


Figura 4.24: Error plot (ao nível de significância de 5%) dos coeficiente de entropia (*Multiscale Sample Entropy*) das séries de velocidade média diária do vento no Brasil (A), e em suas diferentes regiões climáticas (Equatorial (B), Temperado (C), Tropical Brasil Central (D), Tropical Nordeste Oriental (E), Tropical Zona Equatorial (F)), no período de 1990 a 2012, para diferentes expoentes de escala ($\tau = 1, 2, \dots, 30$ dias).



5. CONCLUSÕES

Este trabalho teve como objetivo a observação da regularidade e da autocorrelação do clima no Brasil. Foram estudadas séries diárias de temperatura do ar (máxima, mínima, média e amplitude térmica), umidade relativa média do ar e velocidade média do vento, no período de 1990 a 2012. Estas séries são provenientes de 264 estações meteorológicas, das quais realizamos estimativas das estatísticas de *SampEn* e DFA, e posteriormente, interpolamos os resultados utilizando o *Kriging*, ampliando as estimativas para todo o território brasileiro.

Os valores médios de temperatura máxima, mínima e média do ar apresentaram forte relação com a latitude, onde o maior distanciamento da linha do Equador tende a atenuar as temperaturas, porém a variabilidade destas mesmas variáveis segue o sentido oposto, com maiores estimativas de desvio padrão em áreas mais distantes do Equador. Em resumo, observamos que maiores latitudes tendem a atenuar as médias das temperaturas máxima, mínima e média do ar, porém aumentam a variabilidade das mesmas. Esta inversão entre as magnitudes da média e do desvio padrão também é observado na umidade relativa média do ar, onde os locais com maiores médias diárias coincidiram com aqueles com menores variabilidades. Para a amplitude térmica e a velocidade média diária do vento observou-se que as áreas com maiores valores de desvio padrão coincidem com aqueles que apresentaram maiores médias diárias.

Em geral, as variáveis de temperatura do ar apontaram um maior alcance da autocorrelação com a maior proximidade da linha do Equador. Demais fatores climáticos como a maritimidade, altitude, relevo e vegetação não foram observados como influentes nesta autocorrelação. Em média, os expoentes de Hurst estimados no Brasil para a temperatura média, máxima, mínima e amplitude térmica do ar, respectivamente, foram de 0,81; 0,79; 0,81 e 0,77. A disposição do expoente de Hurts no Brasil para a umidade relativa média do ar e a velocidade média diária do vento não mostraram correlação com nenhum dos fatores climáticos citados. A umidade relativa média diária do ar foi a variável que apresentou o maior valor médio do expoente de Hurst (0,83), sendo caracterizada como a variável de maior “memória”. Chama-se a atenção para o comportamento da velocidade média do vento, com curto alcance

da autocorrelação em quase todo território brasileiro (média de 0,64 do expoente de Hurst), e com regiões caracterizadas com comportamento aleatório.

As regularidades das séries climáticas no Brasil foram medianas. Para $\tau = 1$, os valores médios do *SampEn* estimado foram de 1,39, 1,78, 1,46, 1,41, 1,56 e 1,66, respectivamente para a temperatura média do ar, a amplitude térmica, as temperaturas máxima e mínima do ar, a umidade relativa média do ar e a velocidade média do vento. Especialmente, as maiores alterações nas estimativas das entropias deu-se da escala 1 para a 2 de τ . A partir de $\tau \geq 2$ as mudanças observadas foram mais sutis. Não observamos correlação entre as estimativas de entropia com os fatores de maritimidade, altitude, vegetação e relevo. Para a temperatura média diária do ar e a temperatura máxima diária do ar, há indícios de possíveis influências da massa de ar Equatorial Continental sob o fenômeno. Já a amplitude térmica diária apresentou relação com a altitude, para valores de $\tau \geq 4$.

Ao discriminar, segundo as regiões climáticas do Brasil, os resultados obtidos com o MSE, notamos que algumas regiões climáticas apresentaram flutuações da entropia estimada diferentes do observado para todo o território brasileiro. Nas variáveis temperatura média do ar, máxima e amplitude térmica, somente as flutuações observadas nas zonas de clima Temperado e Tropical Brasil Central foram semelhantes àquelas observadas considerando a média da entropia em todo o Brasil. Na variável temperatura mínima do ar, esta discordância ocorreu apenas na região de clima Temperado. As variáveis umidade relativa do ar e velocidade média do vento apresentaram comportamentos opostos, enquanto na primeira as médias de entropia apresentaram flutuações semelhantes ao observado para todo Brasil apenas nas zonas de clima Tropical Nordeste Oriental e Tropical Zona Equatorial, na outra variável esta similaridade ocorreu somente nas demais zonas climáticas, Equatorial, Temperada e Tropical Brasil Central.

Dentre os fatores climáticos avaliados, a latitude foi aquele que interferiu com maior frequência nos resultados observados, principalmente nas variáveis de temperatura, tanto na análise descritiva, quanto na avaliação da entropia e da autocorrelação de longo alcance das séries estudadas. Em alguns casos, a maritimidade e as massas de ar também foram apontados como fatores importantes na caracterização da distribuição espacial das estimativas realizadas.

Não foi observado em nenhum caso interferências do relevo, da altitude, da vegetação e das correntes marítimas. Esta ausência de correlação não implica que estes não sejam fatores climáticos importantes. Em nosso trabalho avaliamos de uma forma global a distribuição espacial destas estatísticas, estudos locais podem apontar influência destes fatores climáticos sob estas mesmas estatísticas estimadas.

Como trabalhos futuros, podem-se analisar estas mesmas séries mensalmente. Tal abordagem pode ressaltar características não observadas neste estudo, como a influência das estações do ano, além de que pode possibilitar uma melhor observação da influência das massas de ar, que agem de forma diferente conforme as estações do ano.

6. REFERÊNCIA

1. AYOADE, J. O. **Introdução à Climatologia para os Trópicos**. 4. ed. Rio de Janeiro: Bertrand Brasil, 1996.
2. MENDONÇA, F.; DANNI-OLIVEIRA, I. M. **Climatologia: noções básicas e climas do Brasil**. São Paulo: Oficina de Textos, 2007.
3. DIAS, F. L. F. et al. Produtividade da cana-de-açúcar em relação a clima e solos da região Nordeste do estado de São Paulo. **Revista Brasileira de Ciência do Solo**, v. 23, p. 627-634, 1999.
4. RODRIGUES, M. L. G.; FRANCO, D.; SUGAHARA, S. Climatologia de frentes frias no litoral de Santa Catarina. **Revista Brasileira de Geofísica**, v. 22, n. 2, p. 135-151, 2004.
5. BENICIO, R. B. D. et al. Multifractal behavior of wild-land and forest fire time series in Brazil. **Physica A**, v. 392, p. 6367–6374, 2013.
6. INSTITUTO NACIONAL DE METEOROLOGIA (INMET). Informações sobre o tempo, 2013. Disponível em: <http://www.inmet.gov.br/html/informacoes/curiosidade/sobre_tempo.html>. Acesso em: 24 nov. 2013.
7. BEZERRA, A. N.; PEZZI, L. P.; KAYANO, M. T. Esquema estatístico de combinação e correção de previsões climáticas - ECCOCLIM. **Revista Brasileira de Meteorologia**, v. 23, n. 3, p. 347-359, 2008.
8. ROPELEWSKI, C. F.; HALPERT, M. S. Global and regional scale precipitation patterns associated with the El Niño/Southern Oscillation. **Monthly Weather Review**, v. 115, p. 1606-1626, 1987.
9. ROPELEWSKI, C. F.; HALPERT, M. S. Precipitation patterns associated with the high index phase of the Southern Oscillation. **Journal of Climate**, v. 2, p. 268-284, 1989.
10. TUCCI, C. E. M. **Impactos da Variabilidade Climática e Uso do Solo Sobre os Recursos Hídricos**. Agência Nacional das Águas - ANA. Brasília - DF, p. 150. 2002.
11. INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Climate Change 2001: Impacts, Adaptation and Vulnerability**. Cambridge University Press. Cambridge. 2001.
12. PINTO, H. S. et al. **Variabilidade Climática**. Água, Agricultura e Meio Ambiente no Estado de São Paulo: Avanços e Desafios. Jaguariúna - SP: EMBRAPA. 2003. p. 1-13.
13. INSTITUTO NACIONAL DE METEOROLOGIA (INMET). Tempo e Clima, 2013. Disponível em: <http://www.inmet.gov.br/html/informacoes/curiosidade/tempo_clima.html>. Acesso em: 15 nov. 2013.

14. SANTOS, M. D. O.; STOSIC, B. D.; STOSIC, T. Long-term correlations in hourly wind speed records in Pernambuco, Brazil. **Physica. A**, v. 391, p. 1546-1552, 2012.
15. MESOMMO, D.; DINIZ, G. B. Análise espectral da temperatura mínima média em dois trimestres numa região homogêneas do Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, v. 15, p. 121-132, 2007.
16. DINIZ, G. B. et al. Identificação de regiões homogêneas de temperaturas máxima e mínima do Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, v. 11, n. 2, p. 303-312, 2003.
17. BACK, Á. J. Aplicação de análise estatística para identificação de tendências climáticas. **Revista Pesquisa Agropecuária Brasileira**, v. 36, n. 5, p. 717-726, 2001.
18. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). IBGE - Downloads, 2014. Disponível em: <http://downloads.ibge.gov.br/downloads_geociencias.htm>. Acesso em: 05 ago. 2014.
19. VAREJÃO-SILVA, M. A. **Meteorologia e Climatologia**. Recife: Versão Digital, v. 2, 2006.
20. JONSSON, P. Wind erosion on sugar beet fields in Scania, southern Sweden. **Agricultural and Forest Meteorology**, v. 62, p. 141-157, 1992.
21. LIU, L. Y. et al. Dune sand transport as influenced by wind directions, speed and frequencies in the Ordos Plateau, China. **Geomorphology**, v. 67, p. 283-297, 2005.
22. DEMIRCI, E.; CUHADAROGLY, B. Statistical analysis of wind circulation and air pollution in urban Trabzon. **Energy and Buildings**, v. 31, p. 49-53, 2000.
23. FRIEDMAN, J.; BARRET, S. C. H. Wind of change: new insights on the ecology and evolution of pollination and mating in wind pollinated plants. **Annals of Botany**, v. 103, p. 1515-1527, 2009.
24. JONGEJANS, E.; TELENIUS, A. Field experiments on seed dispersal by wind in ten umbelliferous species Apiaceae. **Plant Ecology**, v. 152, p. 67-78, 2001.
25. SKIDMORE, E. L.; JACOBS, H. S.; POWERS, W. L. Potential evapotranspiration as influenced by wind. **Agronomy Journal**, v. 61, p. 543-546, 1969.
26. PIMENTA, F.; KEMPTON, W.; GARVINE, R. Combining meteorological stations and satellite data to evaluate offshore wind power resource of Southeastern Brazil. **Renewable Energy**, v. 33, p. 2375-2387, 2008.
27. TORRES, F. T. P.; MACHADO, P. J. O. **Introdução à Climatologia**. Santo André - SP: Geographica, 2008.
28. PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. **Meteorologia Agrícola**. Piracicaba - SP: USP, 2007.

29. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Atlas Geográfico Escolar**. Rio de Janeiro: IBGE, 2002.
30. PINCUS, S. M.; VISCARELLO, R. R. Approximate entropy: a regularity measure for fetal heart rate analysis. **Obstetrics & Gynecology**, v. 79, p. 249-255, 1992.
31. SHANNON, C. E. A mathematical theory of communication. **The Bell System Technical Journal**, v. 27, p. 379-423, 1948.
32. GRASSBERGER, P.; PROCACCIA, I. Estimation of the Kolmogorov entropy from a chaotic signals. **Physical Review A**, v. 28, p. 2591-2593, 1983.
33. RICHMAN, J. S.; MOORMAN, J. R. Physiological time-series analysis using approximate entropy and sample entropy. **Heart and Circulatory Physiology - American Journal of Physiology**, v. 278, p. 2039-2049, 2000.
34. COSTA, M.; GOLDBERGER, A. L.; PENG, C. K. Multiscale entropy analysis for complex physiological time series. **Physical Review Letters**, v. 89, p. 068102, 2002.
35. COSTA, M.; GOLDBERGER, A. L.; PENG, C. K. Multiscale entropy analysis of biological signals. **Physical Review E**, v. 71, p. 021906, 2005.
36. YOO, C. S. et al. Automatic detection of seizure termination during electroconvulsive therapy using sample entropy of the electroencephalogram. **Psychiatry Research**, v. 195, p. 76-82, 2012.
37. MONTIROSSO, R. et al. Infant's emotional variability associated to interactive stressful situation: A novel analysis approach with Sample Entropy and Lempel-Ziv Complexity. **Infant Behavior and Development**, v. 33, n. 3, p. 346(11), 2010.
38. HAUGE, E. R. et al. Nonlinear Analysis of Motor Activity Shows Differences between Schizophrenia and Depression: A Study Using Fourier Analysis and Sample Entropy. **Plos One**, v. 6, n. 1, p. e16291, 2011.
39. HUANG, F. et al. Flow-Complexity Analysis of the Upper Reaches of the Yangtze River, China. **Journal of Hydrologic Engineering**, v. 16, p. 914-919, 2011.
40. MIHAILOVIC, D. T. et al. Complexity analysis of the turbulent environmental fluid flow time series. **Physica A**, v. 395, p. 96-104, 2014.
41. SHUANGCHENG, L. et al. Measurement of climate complexity using sample entropy. **International Journal of Climatology**, v. 26, p. 2131-2139, 2006.
42. KOSSOBOKOV, V.; MOUËL, J.-L. L.; ALLÈGRE, C. Spatial and Temporal Variations of Climate in Europe. **Atmospheric and Climate Sciences**, v. 4, n. 2, p. 568-581, 2012.
43. ZHAO, Z. Q. et al. Identifying spatial patterns and dynamics of climate change using recurrence quantification analysis: a case study of qinghai-tibet plateau. **International Journal Of Bifurcation And Chaos**, v. 21, n. 4, p. 1127-1139, 2011.

44. SILVA, D. A. et al. Caracterização climática de diferentes Biomas brasileiros através do DFA e SampEn. **Anais da 55ª Reunião Anual da Região Brasileira da Sociedade Internacional de Biometria**, São Carlos - SP, 2009.
45. LI, H. et al. **Multi-scale Entropy Analysis of Single-point Wind Speed in Outdoor near-surface Environments**. Beijing: Electrical and Control Engineering, 2011. 4579-4582 p.
46. HURST, H. E. Long Term Storage Capacity of Reservoirs. **Transactions of the American Society of Civil Engineers**, v. 116, p. 770-799, 1951.
47. HURST, H. E. **Long-term storage: An experimental study**. London: Constable, 1965.
48. GRABBE, J. O. Chaos & Fractals in Financial Markets. **The Laissez Faire City Times**, v. 3, n. 29, p. 64, 1999.
49. MANDELBROT, B. B.; WALLIS, J. R. Some long-run properties of geophysical records. **Water Resources Research**, v. 5, n. 2, p. 321-340, 1969.
50. FEDER, J. **Fractals**. New York: Plenum Press, 1988.
51. MANDELBROT, B. B. **The Fractal Geometry of Nature**. 1. ed. United States: W. H. Freeman and Company, 1982.
52. BASSINTHWAITGHT, J. B.; LIEBOVITCH, L. S.; BRUCE, J. W. **Fractal Physiology**. New York: Oxford American Physiological Society, 1994.
53. VICSEK, T. **Fractal growth phenomena**. 2. ed. Singapore: World Scientific, 1993.
54. PENG, C.-K. et al. Long-range anticorrelations and non-gaussian behavior of the heartbeat. **Physical Review Letter**, United States, v. 70, p. 1343-1346, 1993.
55. KULISH, V.; SOURIN, A.; SOURINA, O. Human electroencephalograms seen as fractal time series: Mathematical analysis and visualization. **Computers in Biology and Medicine**, v. 36, p. 291-302, 2006.
56. MULLIGAN, R. F. Fractal analysis of highly volatile markets: an application to technology equities. **The Quarterly Review of Economics and Finance**, v. 44, p. 155-179, 2004.
57. LI, W. et al. Financial factor Influence on scaling and memory of trading volume in stock market. **Physical Review E**, v. 84, p. 046112, 2011.
58. SILVA, L. R. D.; STOŠIĆ, T.; STOŠIĆ, B. D. Power law correlations in time series of wild-land and forest fires in Brazil. **International Journal of Remote Sensing**, v. 33, p. 2059-2067, 2012.
59. SIQUEIRA, E. L. et al. Correlations and cross-correlations in the Brazilian agrarian commodities and stocks. **Physica A**, v. 389, p. 2739-2743, 2010.
60. BRESLIN, M. C.; BELWARD, J. A. Fractal dimensions for rainfall time series. **Mathematics and Computers in Simulation**, Amsterdam, v. 48, p. 437-446,

1999.

61. DELIGNIERES, D. et al. Fractal analyses for 'short' time series: A re-assessment of classical methods. **Journal of Mathematical Psychology**, v. 50, p. 525–544, 2006.
62. MANDELBROT, B. B.; NESS, J. W. V. Fractional Brownian motions, fractional noises and applications. **SIAM Review**, v. 10, p. 422–437, 1968.
63. PENG, C.-K. et al. Mosaic organization of DNA nucleotides. **Physic Review E**, v. 49, p. 1685–1689, 1994.
64. BASSINGTHWAIGHTE, J. B. Physiological heterogeneity: Fractals link determinism and randomness in structure and function. **News in Physiological Sciences**, v. 3, p. 5-10, 1988.
65. DERICHE, M.; TEWFIK, A. H. Maximum likelihood estimation of the parameters of discrete fractionally differenced Gaussian noise process. **IEEE Transactions on Signal Processing**, v. 41, p. 2977–2989, 1993.
66. CANNON, M. J. et al. Evaluating scaled windowed variance methods for estimating the Hurst coefficient of time series. **Physica A**, v. 241, p. 606–626, 1997.
67. EKE, A. et al. Physiological time series: Distinguishing fractal noises from motions. **Pflügers Archives**, v. 439, p. 403–415, 2000.
68. FRAEDRICH, K.; BLENDER, R. Scaling of Atmosphere and Ocean Temperature Correlations in Observations and Climate Models. **Physical Review Letters**, v. 90, n. 10, p. 108501, 2003.
69. KOSCIELNY-BUNDE, E. et al. Indication of a Universal Persistence Law Governing Atmospheric Variability. **Physical Review Letters**, v. 81, p. 729–732, 1998.
70. LÜDECKE, H.-J.; LINK, R.; EWERT, F.-K. How Natural is the Recent Centennial Warming? An Analysis of 2249 Surface Temperature Records. **International Journal of Modern Physics C**, v. 22, p. 1139-1159, 2011.
71. CHEN, X.; LIN, G.; FU, Z. Long-range correlations in daily relative humidity fluctuations: A new index to characterize the climate regions over China. **Geophysical Research Letters**, v. 34, p. L07804, 2007.
72. GOVINDAN, R. B. et al. Global climate models violate scaling of the observed atmospheric variability. **Physical Review Letters**, v. 89, p. 028501, 2002.
73. BLENDER, R.; FRAEDRICH, K. Long-time memory in global warming simulations. **Geophysical Research Letters**, v. 30, p. L1769, 2003.
74. VYUSHIN, D. et al. Volcanic forcing improves atmosphere-ocean coupled general circulation model scaling performance. **Geophysical Research Letters**, v. 31, p. L10206, 2004.
75. WEBER, R.; TALKNER, P. Spectra and correlations of climate data from days to decades. **Journal of Geophysical Research**, v. 106, p. 20131-20144, 2001.

76. ECHNER, J. F. et al. Power-law persistence and trends in the atmosphere: A detailed study of long temperature records. **Physical Review E**, v. 68, p. 046133, 2003.
77. KIRALY, A.; JANOSI, I. M. Detrended fluctuation analysis of daily temperature records: Geographic dependence over Australia. **Meteorology and Atmospheric Physics**, v. 88, p. 119-128, 2005.
78. BAKKER, A. M. R.; HURK, B. J. J. M. V. D. Estimation of persistence and trends in geostrophic wind speed for the assessment of wind energy yields in Northwest Europe. **Climate Dynamics**, v. 39, p. 767–782, 2012.
79. TSONIS, A. A.; ROEBBER, P. J.; ELSNER, J. B. Long-Range Correlations in the Extratropical Atmospheric Circulation: Origins and Implications. **Journal of Climate**, v. 12, p. 1534-1541, 1999.
80. KRIGE, D. G. A statistical approach to some basic mine valuation problems on the Witwatersrand. **Journal of the Chemical, Metallurgical and Mining Society of South Africa**, v. 52, p. 119-139, 1951.
81. MATHERON, G. Principles of geostatistics. **Economic Geology**, v. 58, p. 1246-1266, 1963.
82. CÂMARA, G.; MEDEIROS, J. S. Princípios básicos em geoprocessamento. In: ASSAD, E. D.; SANO, E. E. **Sistemas de informações geográficas: aplicações na agricultura**. 2. ed. Brasília - DF: Embrapa-SPI: Embrapa-CPAC, 1998. p. 3-11.
83. ZIMBACK, C. R. L. **Geoestatística**. Botucatu: UNESP, 2003.
84. LAM, N. Spatial interpolation methods. **The American Cartographer**, v. 10, p. 129-149, 1983.
85. ISAAKS, E. H.; SERIVASTAVA, M. **An introduction to applied geostatistics**. New York: Oxford University Press, 1989.
86. BROOKERS, P. I. **A geostatistical primer**. Londres: World Scientific, 1991.
87. GOTWAY, C. A. et al. Comparison of kriging and inverse-distance methods for mapping soil parameters. **Soil Science Society of America Journal**, v. 60, p. 1237-1247, 1996.
88. MYERS, D. E. Interpolation and estimation with spatially located data. **Chemometrics and Intelligent Laboratory Systems**, v. 11, p. 209-228, 1991.
89. MATHERON, G. **The theory of regionalized variables and its applications**. Paris: Les Cahiers du Centre de Morphologie Mathématique de Fontainebleu, 1971.
90. SHEPARD, D. A two-dimensional interpolation function for irregularly-spaced data. In: BLUE, S. R. B.; ROSENBERG, A. M. **Proceedings of the 1968 23rd ACM national conference**. New York: ACM Press, 1968. p. 517–524.
91. LI, J.; HEAP, A. D. **A Review of Spatial Interpolation Methods for Environmental Scientists**. Canberra: Geoscience Australia, Record, 2008.

92. APAYDIN, H.; SONMEZ, F. K.; YILDIRIM, Y. E. Spatial interpolation techniques for climate data in the GAP region in Turkey. **Climate Research**, v. 28, p. 31-40, 2004.
93. NUSRET, D.; ĐUG, S. **Applying the Inverse Distance Weighting and Kriging methods of the spatial interpolation on the mapping the annual precipitation in Bosnia and Herzegovina**. International Environmental Modelling and Software Society. Leipzig, Alemanha. 2012.
94. LUO, W.; TAYLOR, M. C.; PARKER, S. R. A comparison of spatial interpolation methods to estimate continuous wind speed surfaces using irregularly distributed data from England and Wales. **International Journal of Climatology**, v. 28, p. 947-959, 2008.
95. LI, T. et al. Mapping near-surface air temperature, pressure, relative humidity and wind speed over Mainland China with high spatiotemporal resolution. **Advances in Atmospheric Sciences**, v. 31, n. 5, p. 1127-1135, 2014.
96. TIETAVAINEN, H.; TUOMENVIRTA, H.; VENALAINEN, A. Annual and seasonal mean temperatures in Finland during the last 160 years based on gridded temperature data. **International Journal of Climatology**, v. 30, n. 15, p. 2247–2256, 2010.
97. APAYDIN, H.; ANLI, A. S.; OZTURK, F. Evaluation of topographical and geographical effects on some climatic parameters in the Central Anatolia Region of Turkey. **International Journal of Climatology**, v. 31, n. 9, p. 1264-1279, 2011.
98. ZHANG, K. et al. Geostatistical exploration of spatial variation of summertime temperatures in the Detroit metropolitan region. **Environmental Research**, v. 111, n. 8, p. 1046-1053, 2011.
99. CARRERA-HERNÁNDEZ, J. J.; GASKIN, S. J. Spatio temporal analysis of daily precipitation and temperature in the Basin of Mexico. **Journal of Hydrology**, v. 336, n. 3-4, p. 231 -249, 2007.
100. MIETUS, J. E.; PENG, C. K.; MOODY, G. B. Detrended Fluctuation Analysis (DFA). **Physionet**, 2003. Disponível em: <<http://www.physionet.org/physiotools/dfa/>>. Acesso em: 25 dez. 2013.
101. LAKE, D. K.; MOORMAN, J. R.; HANQING, C. Sample Entropy estimation using sampen. **Physionet**, 2012. Disponível em: <<http://physionet.org/physiotools/sampen/>>. Acesso em: 25 dez. 2013.
102. TANG, X.-J. et al. Complexity measurements of electroencephalograph recordings using sample entropy algorithm in patients with temporal lobe epilepsy. **Acta Biophysica Sinica**, v. 20, p. 382-392, 2004.
103. PINCUS, S. M. Approximate entropy as a measure of system complexity. **Proceedings of the National Academy of Sciences**, v. 88, p. 2297-2301, 1991.
104. PENG, C. K. et al. Quantification of scaling exponents and crossover heartbeat time series. **Chaos**, United States, v. 5, n. 1, p. 82-87, 1995.

105. IVANOV, P. C. Scaling behaviors of Heartbeat Intervals obtained by Wavelet-Based Time-Series Analysis. **Nature**, England, v. 383, p. 323-327, 1996.
106. IVANOVA, K.; AUSLOOS, M. Application of the detrended fluctuation analysis (DFA) method for describing cloud breaking. **Physica A**, Netherlands, v. 274, n. 1, p. 349-354, 1999.
107. PATTANTYÚS-ÁBRAHÁM, M.; KIRÁLY, A.; JÁNOSI, I. M. Nonuniversal atmospheric persistence: Different scaling of daily minimum and maximum temperatures. **Physical Review E**, United States, v. 69, n. 2, p. 021110, 2004.
108. COSTA, R. L.; VASCONCELOS, G. L. Long-range correlations and nonstationarity in Brazilian stock market. **Physica A**, Netherlands, v. 329, n. 1-2, p. 231-248, 2003.
109. LIU, Y. et al. Quantification of correlations in economic time series. **Physica A**, Netherlands, v. 245, p. 437-440, 1997.
110. LIU, Y. et al. Statistical properties of the volatility of price fluctuations. **Physical Review E**, v. 60, n. 2, p. 1390-1400, 1999.
111. OLEA, R. A. **Geostatistics for Engineers and Earth Scientists**. Boston: Kluwer Academic Publishers, 1999.
112. WEBSTER, R.; OLIVER, M. **Geostatistics for Environmental Scientists**. 2. ed. Chichester: John Wiley & Sons, 2001. 271 p.
113. JOURNEL, A. G.; HUIJBREGTS, C. J. **Mining geostatistics**. London: Academic Press, 1978.
114. KITANIDIS, P. K. **Introduction to Geostatistics: Applications in Hydrogeology**. New York: Cambridge University Press, 1997.
115. CRESSIE, N. **Statistics for spatial data**. New York: John Wiley and Sons, 1991.
116. PANNATIER, Y. **Variowin: Software for Spatial Data Analysis in 2D**. New York: Springer Verlag, 1996.
117. ALFARO, M. The Random Coin Method: Solution of the Problem of the Simulation of a Random Function in the Plane. **Mathematical Geology**, v. 12, n. 1, p. 25-32, 1980.
118. BURGESS, T. M.; WEBSTER, R. Optimal interpolation and isarithmic mapping of soil properties. 1. The semivariogram and punctual kriging. **Journal of Soil Science**, v. 31, n. 2, p. 315 - 331, 1980.
119. JOURNEL, A. G. **Fundamentals of geostatistics in five lessons**. California: Stanford Center for Reservoir Forecasting Applied Earth Sciences Department, 1988.
120. LUTGENS, F. K.; TARBUCC, E. J. **The Atmosphere: an introduction to Meteorology**. 12. ed. California - USA: Prentice Hall, 2012.
121. YOST, R. S.; UEHARA, G.; FOX, R. L. Geostatistical analysis of soil chemical properties of large land areas. II. Kriging. **Mathematical Geology**, v. 46, p.

1033-1037, 1982.

7. APÊNDICE

Figura 7.1: Variogramas das séries de médias da temperatura média diária do ar (A), amplitude térmica diária do ar (B), temperatura máxima diária do ar (C), temperatura mínima diária do ar (D), umidade relativa média diária do ar (E) e velocidade média diária do vento (F), no Brasil, no período de 1990 a 2012.

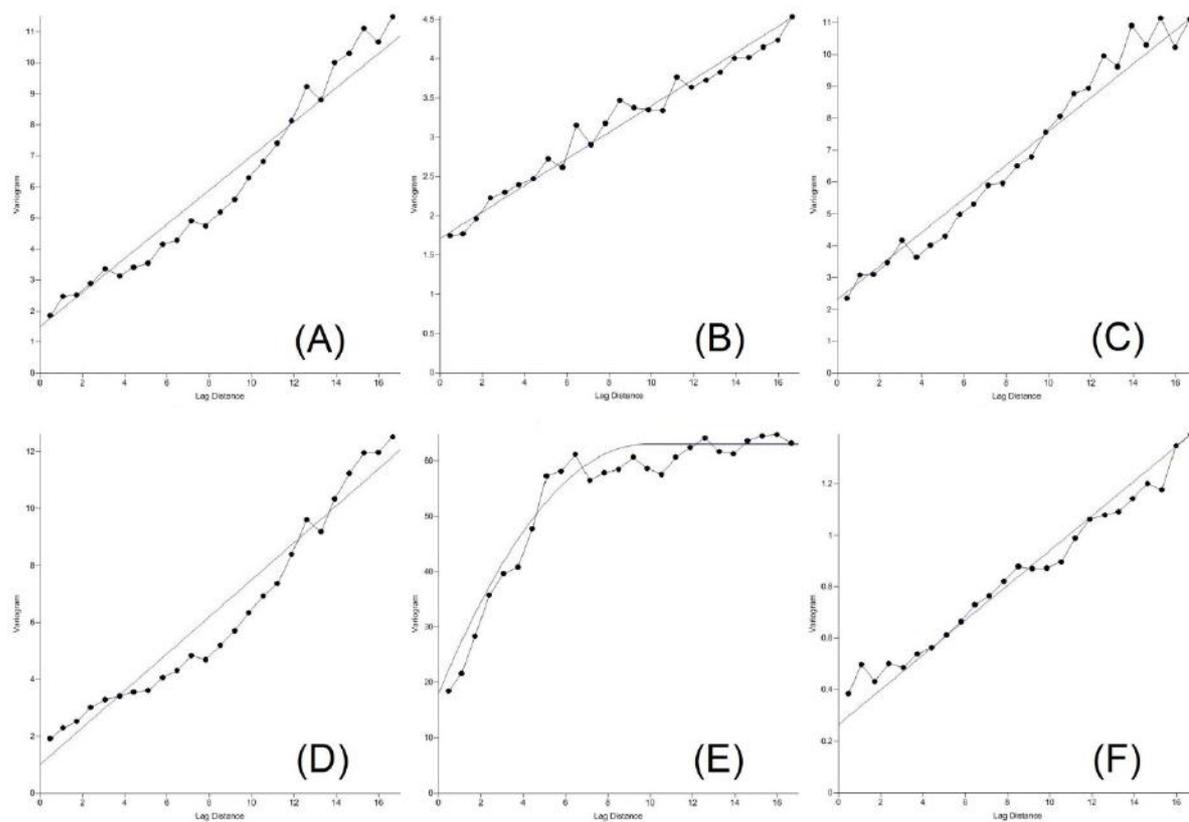


Figura 7.2: Variogramas das séries de desvio padrão da temperatura média diária do ar (A), amplitude térmica diária do ar (B), temperatura máxima diária do air (C), temperatura mínima diária do ar (D), umidade relativa média diária do ar (E) e velocidade média diária do vento (F), no Brasil, no período de 1990 a 2012.

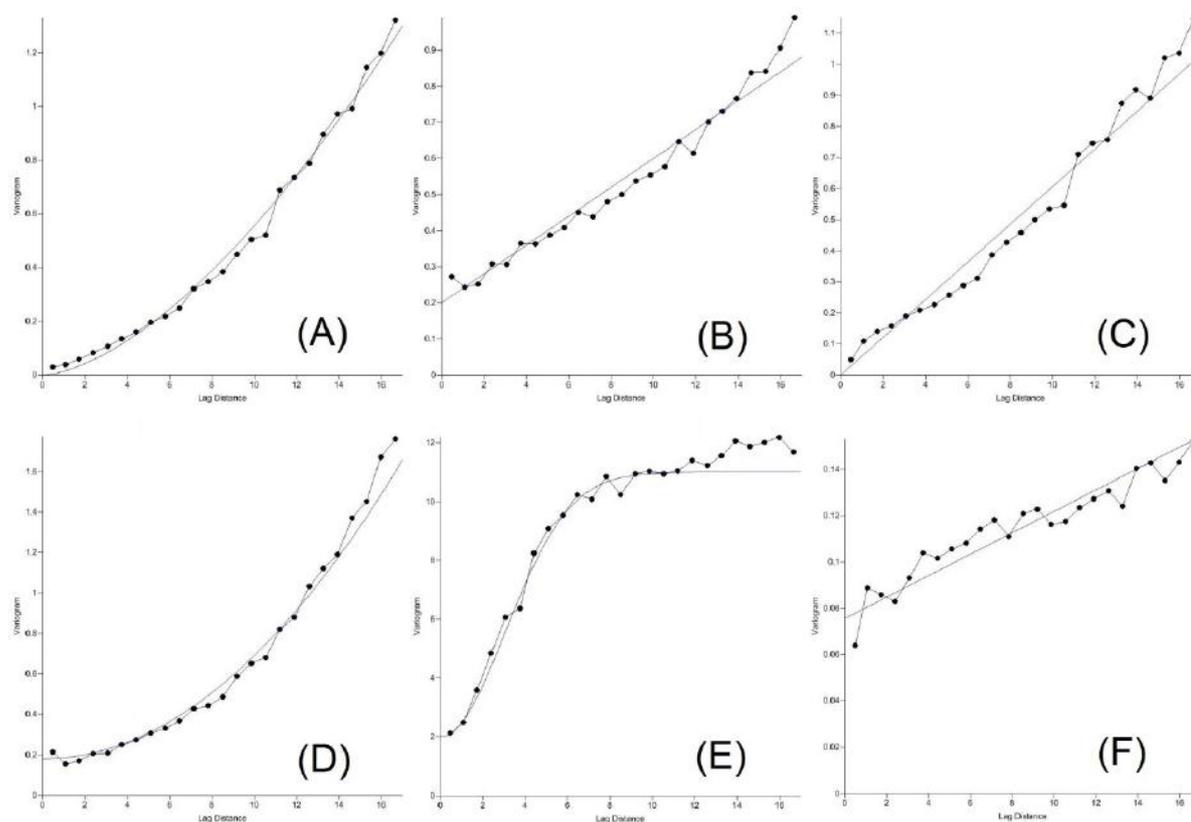


Figura 7.3: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de média diária temperatura do ar no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).

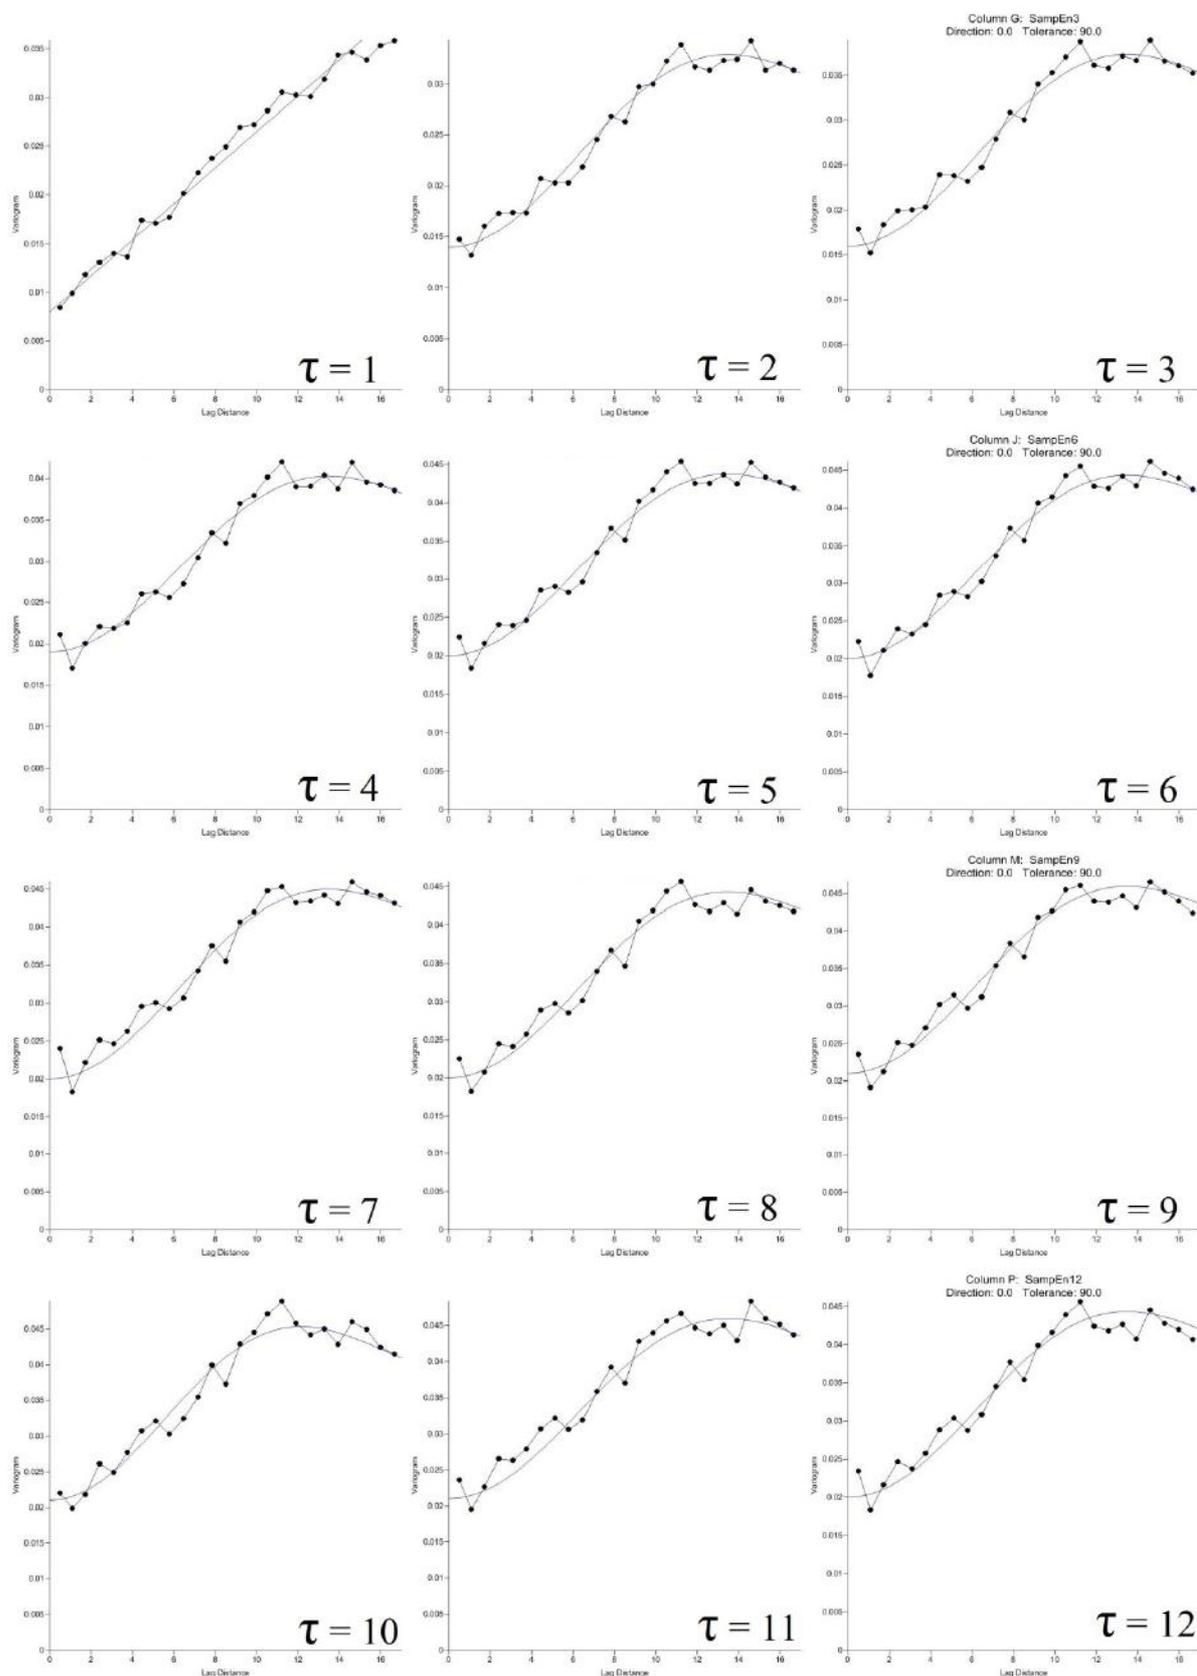


Figura 7.3: Continuação.

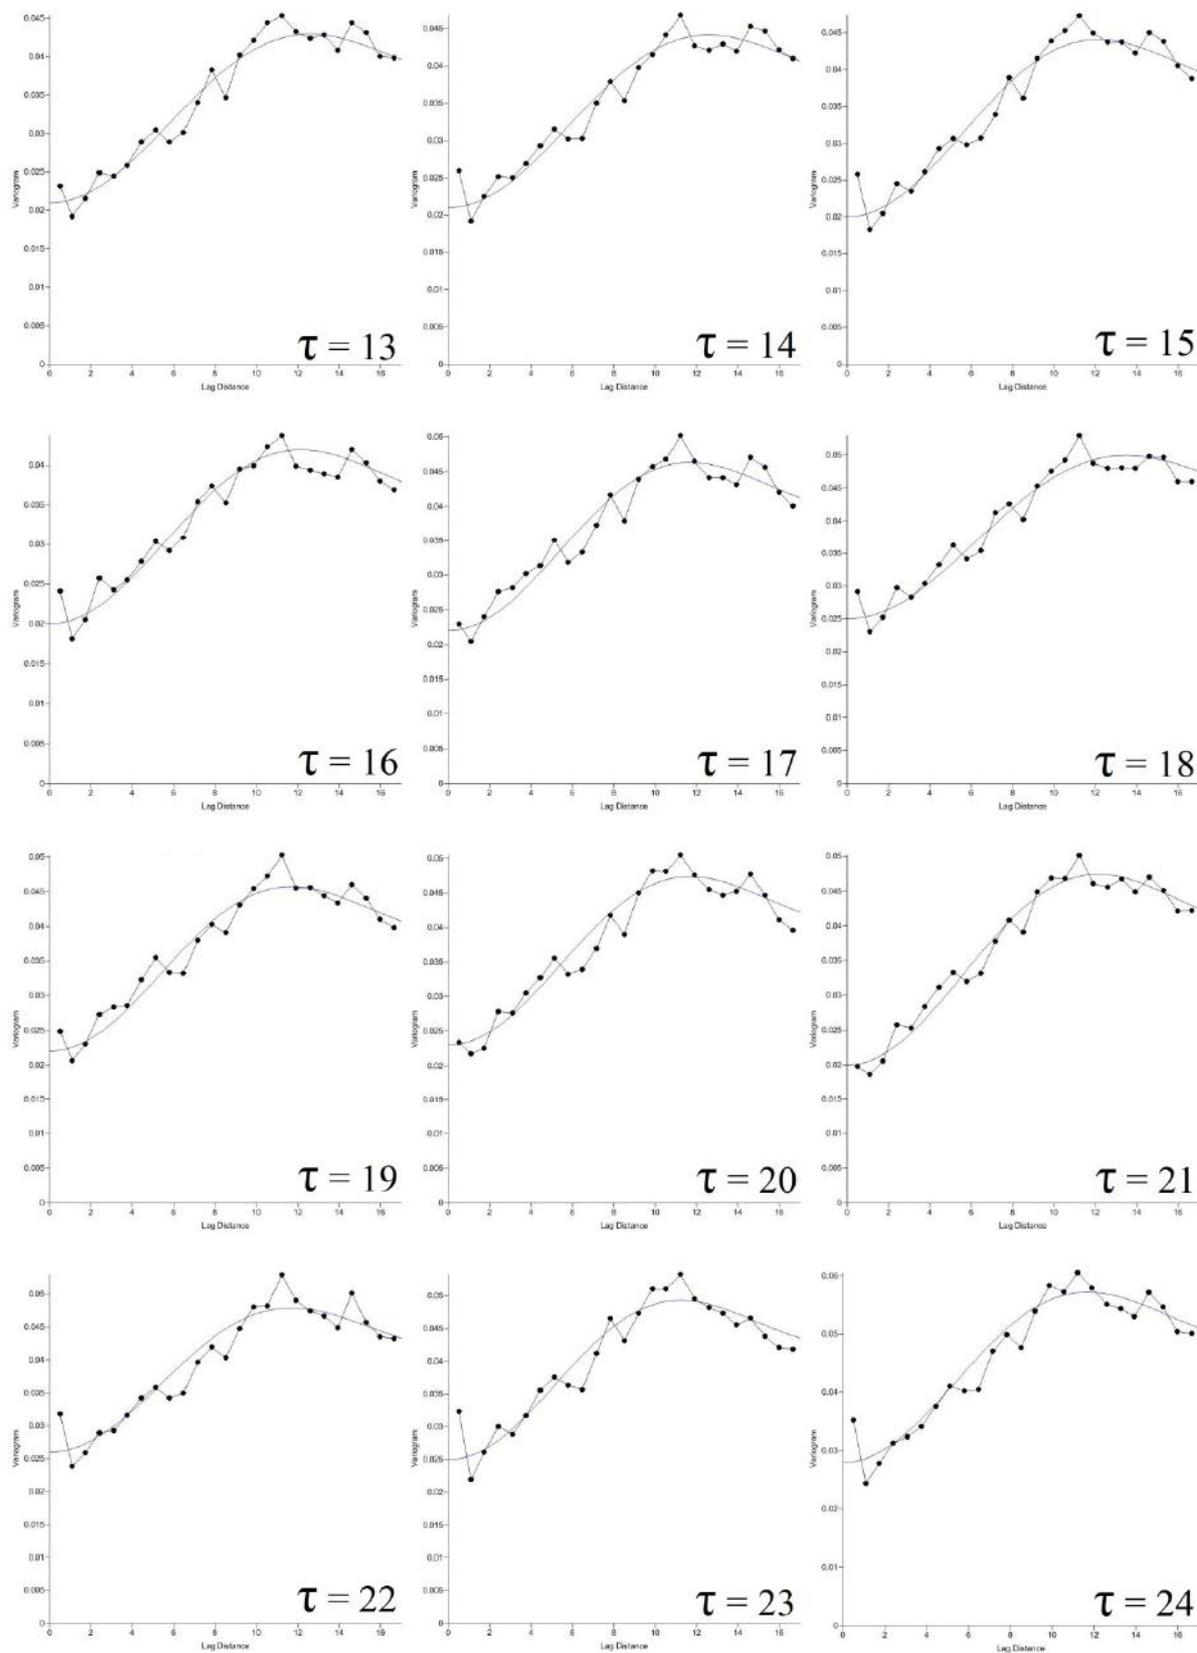


Figura 7.3: Continuação.

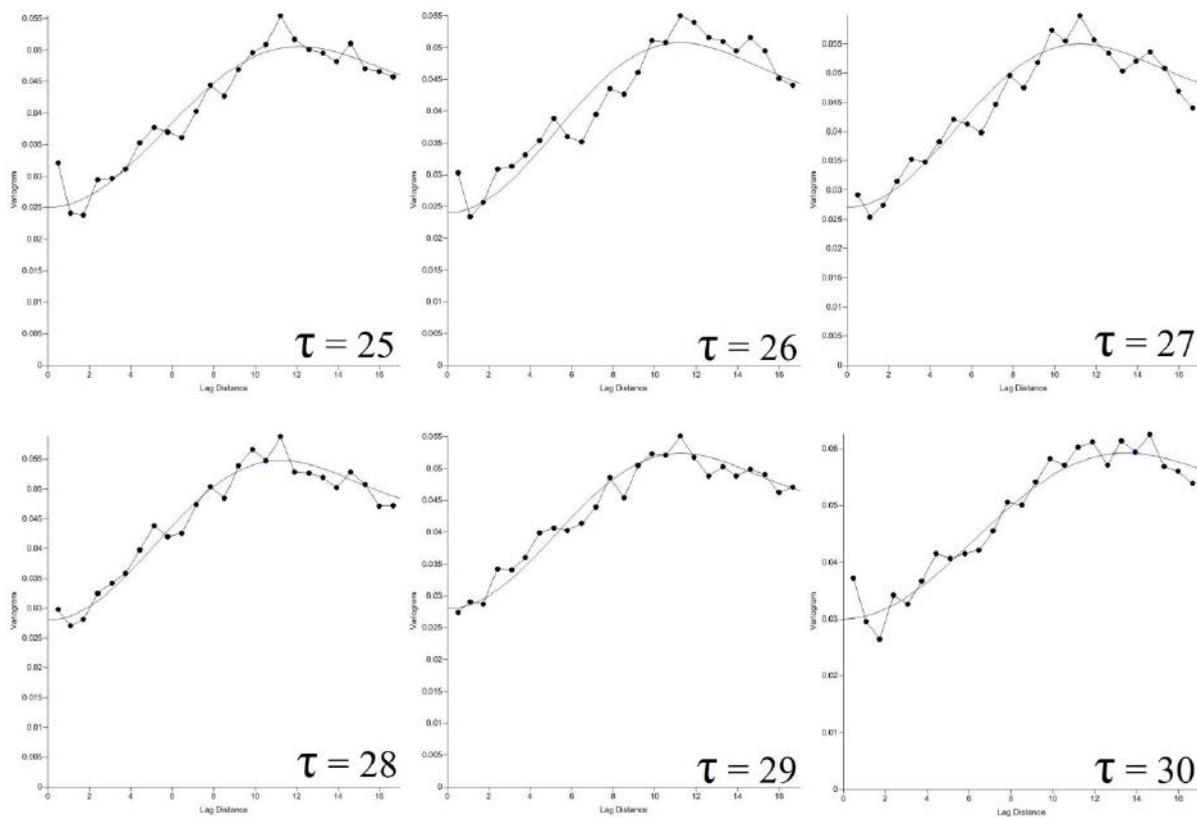


Figura 7.4: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de amplitude térmica diária do ar no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).

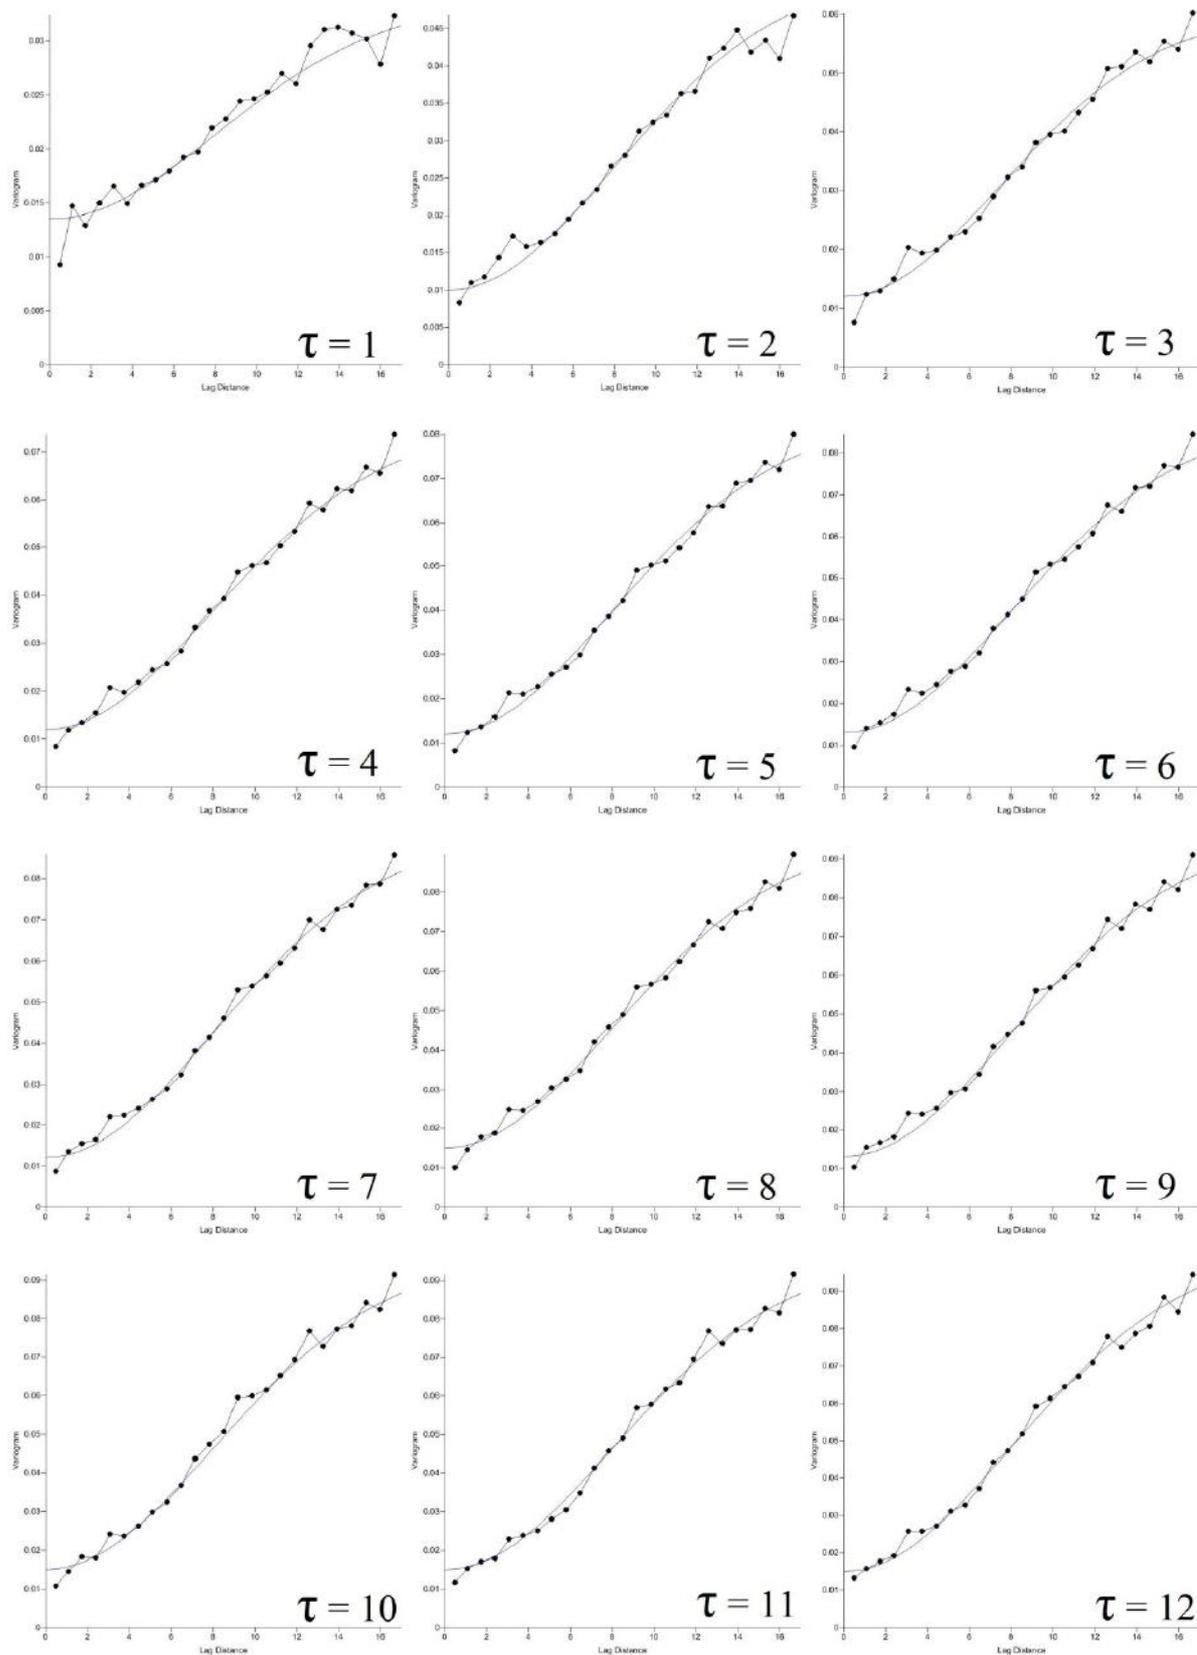


Figura 7.4: Continuação.

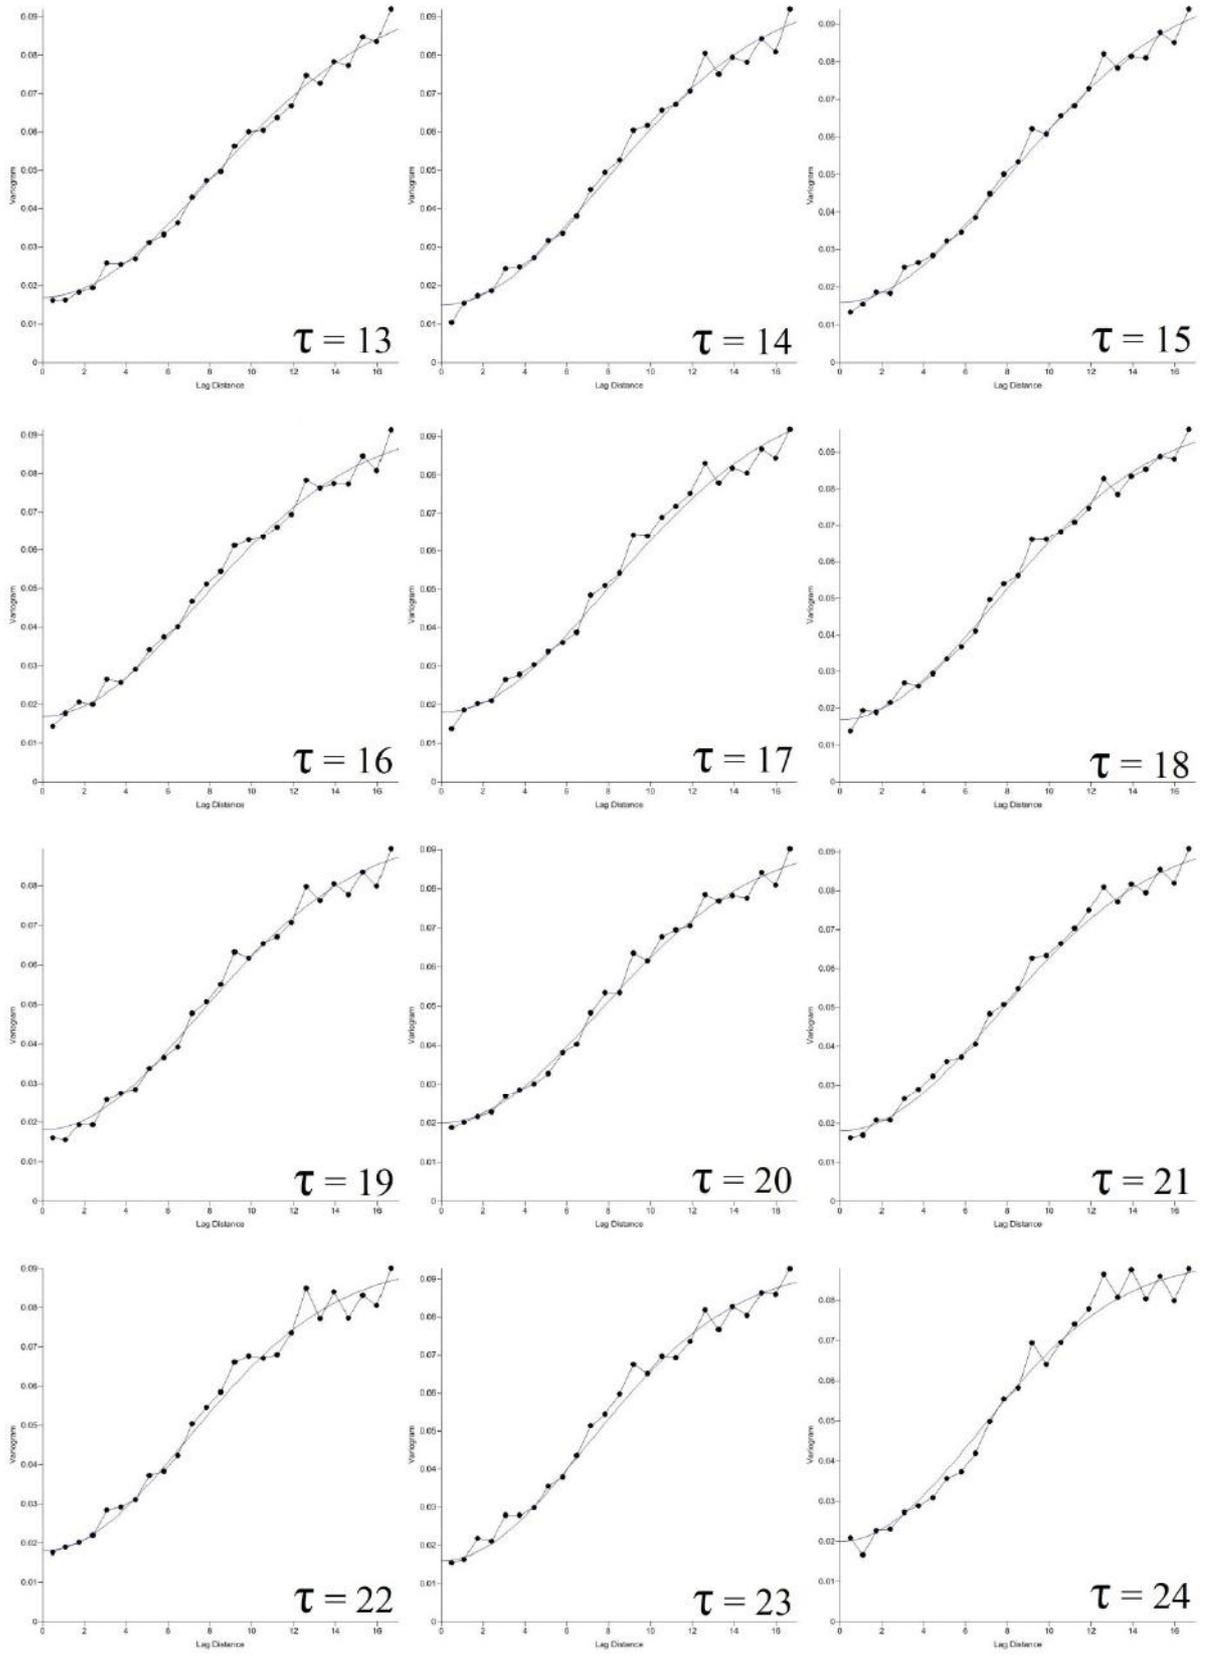


Figura 7.4: Continuação.

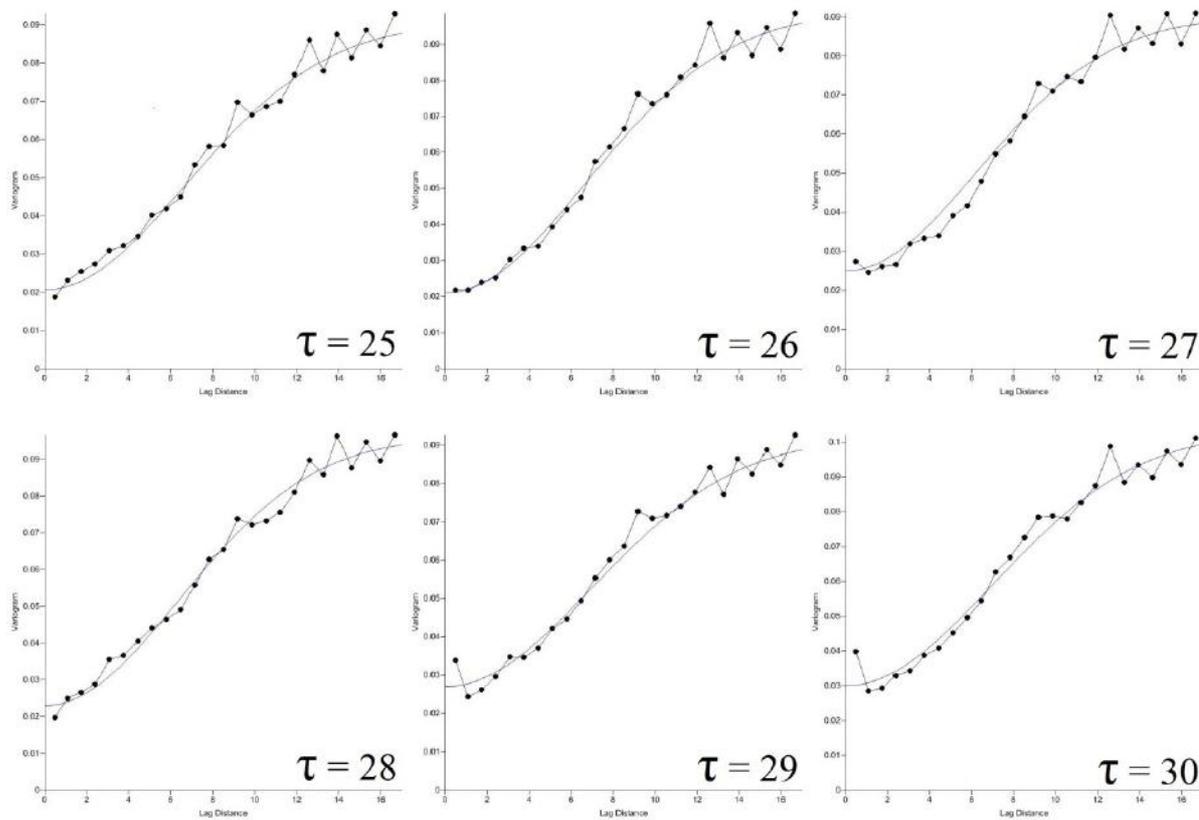


Figura 7.5: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de temperatura máxima diária do ar no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).

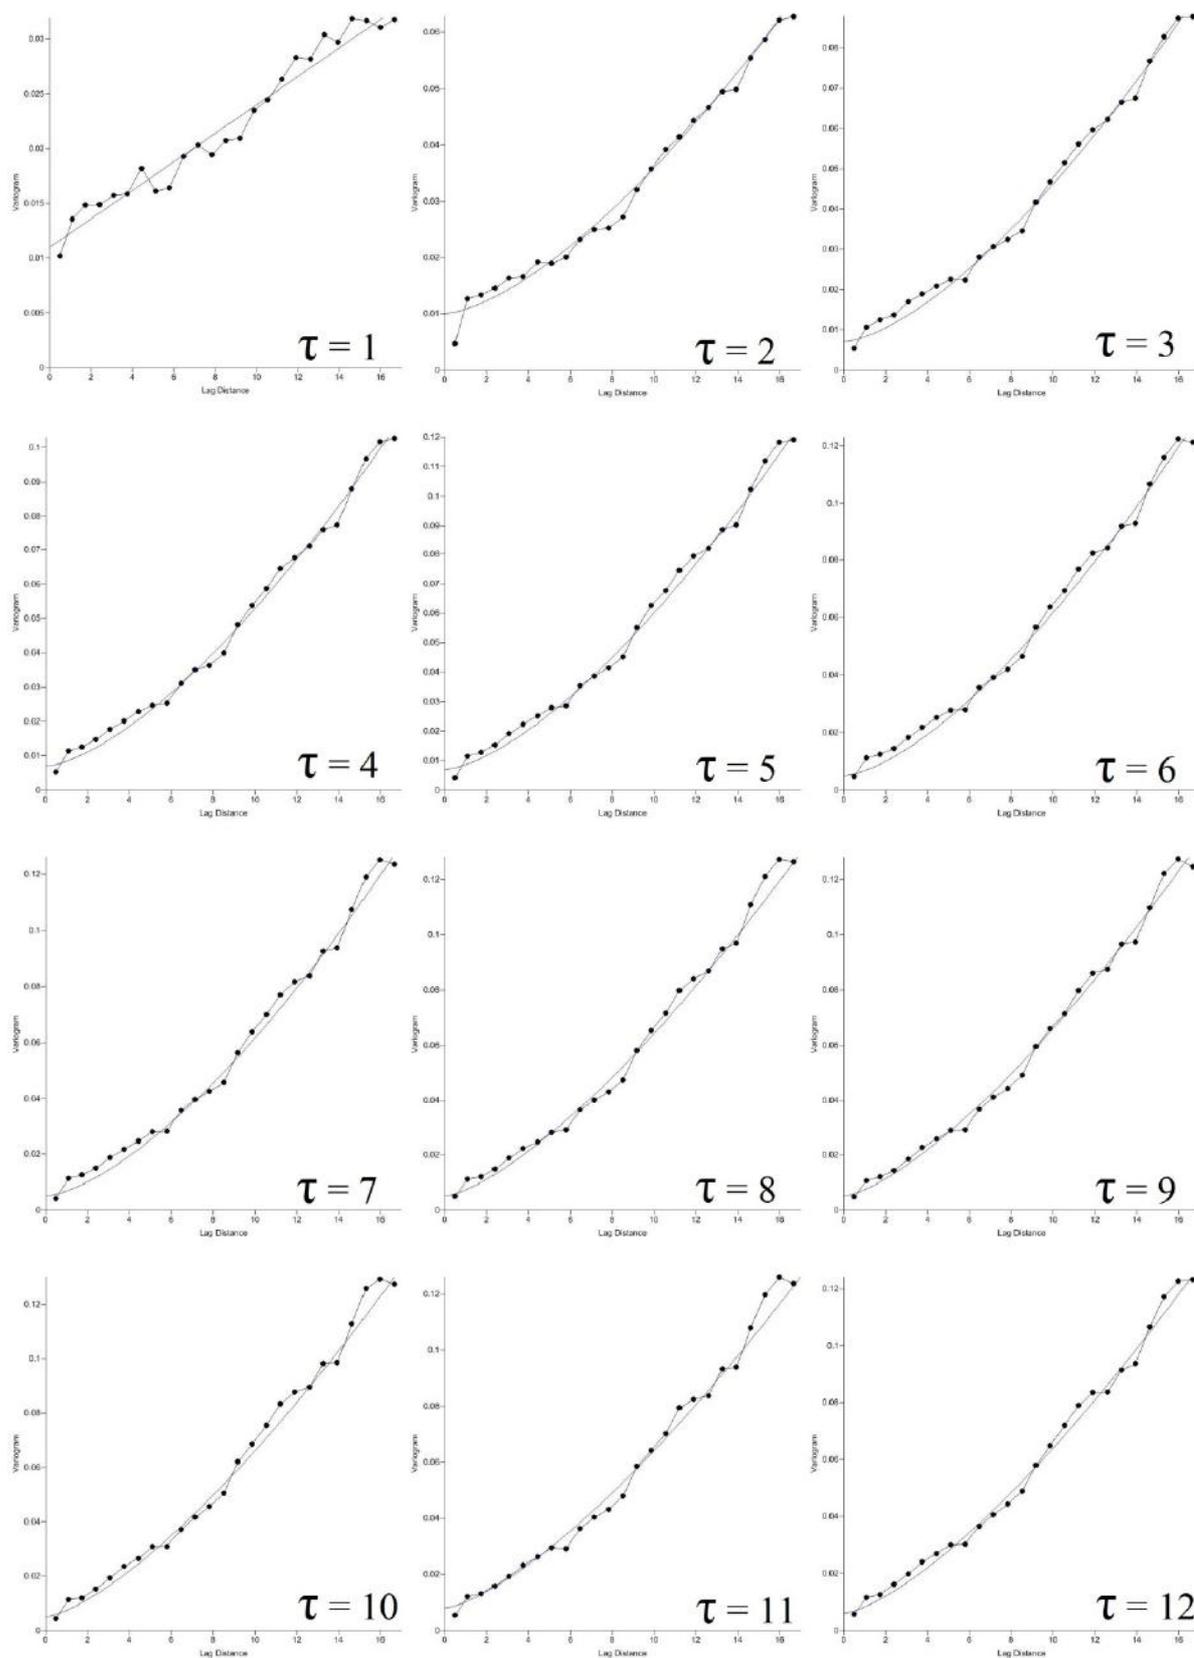


Figura 7.5: Continuação.

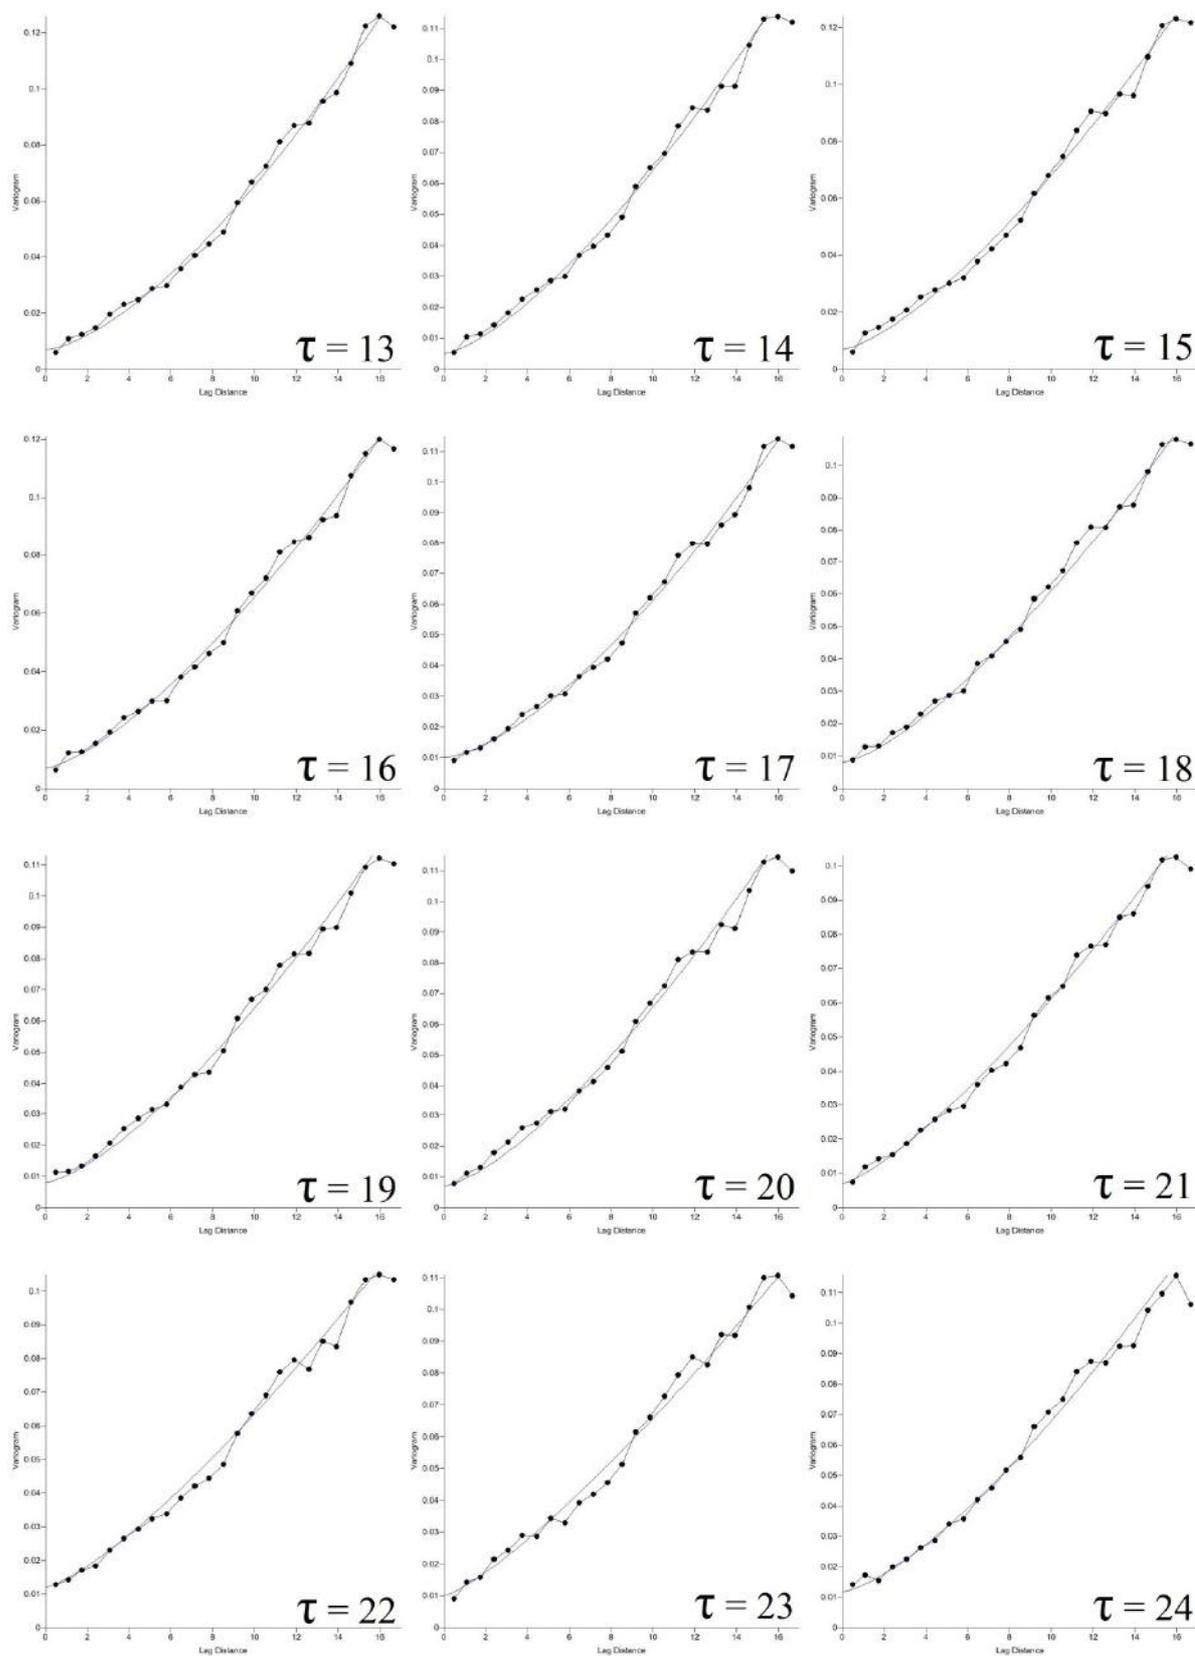


Figura 7.5: Continuação.

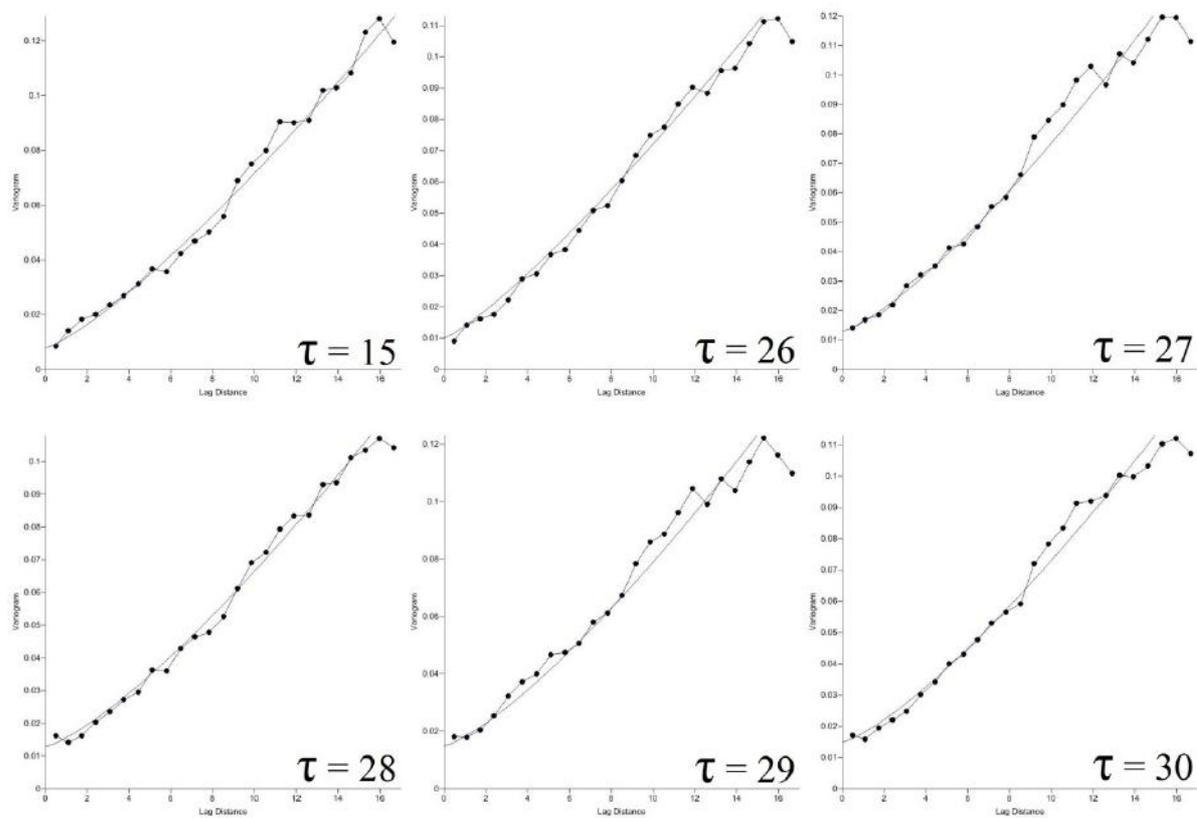


Figura 7.6: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de temperatura mínima diária do ar no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).

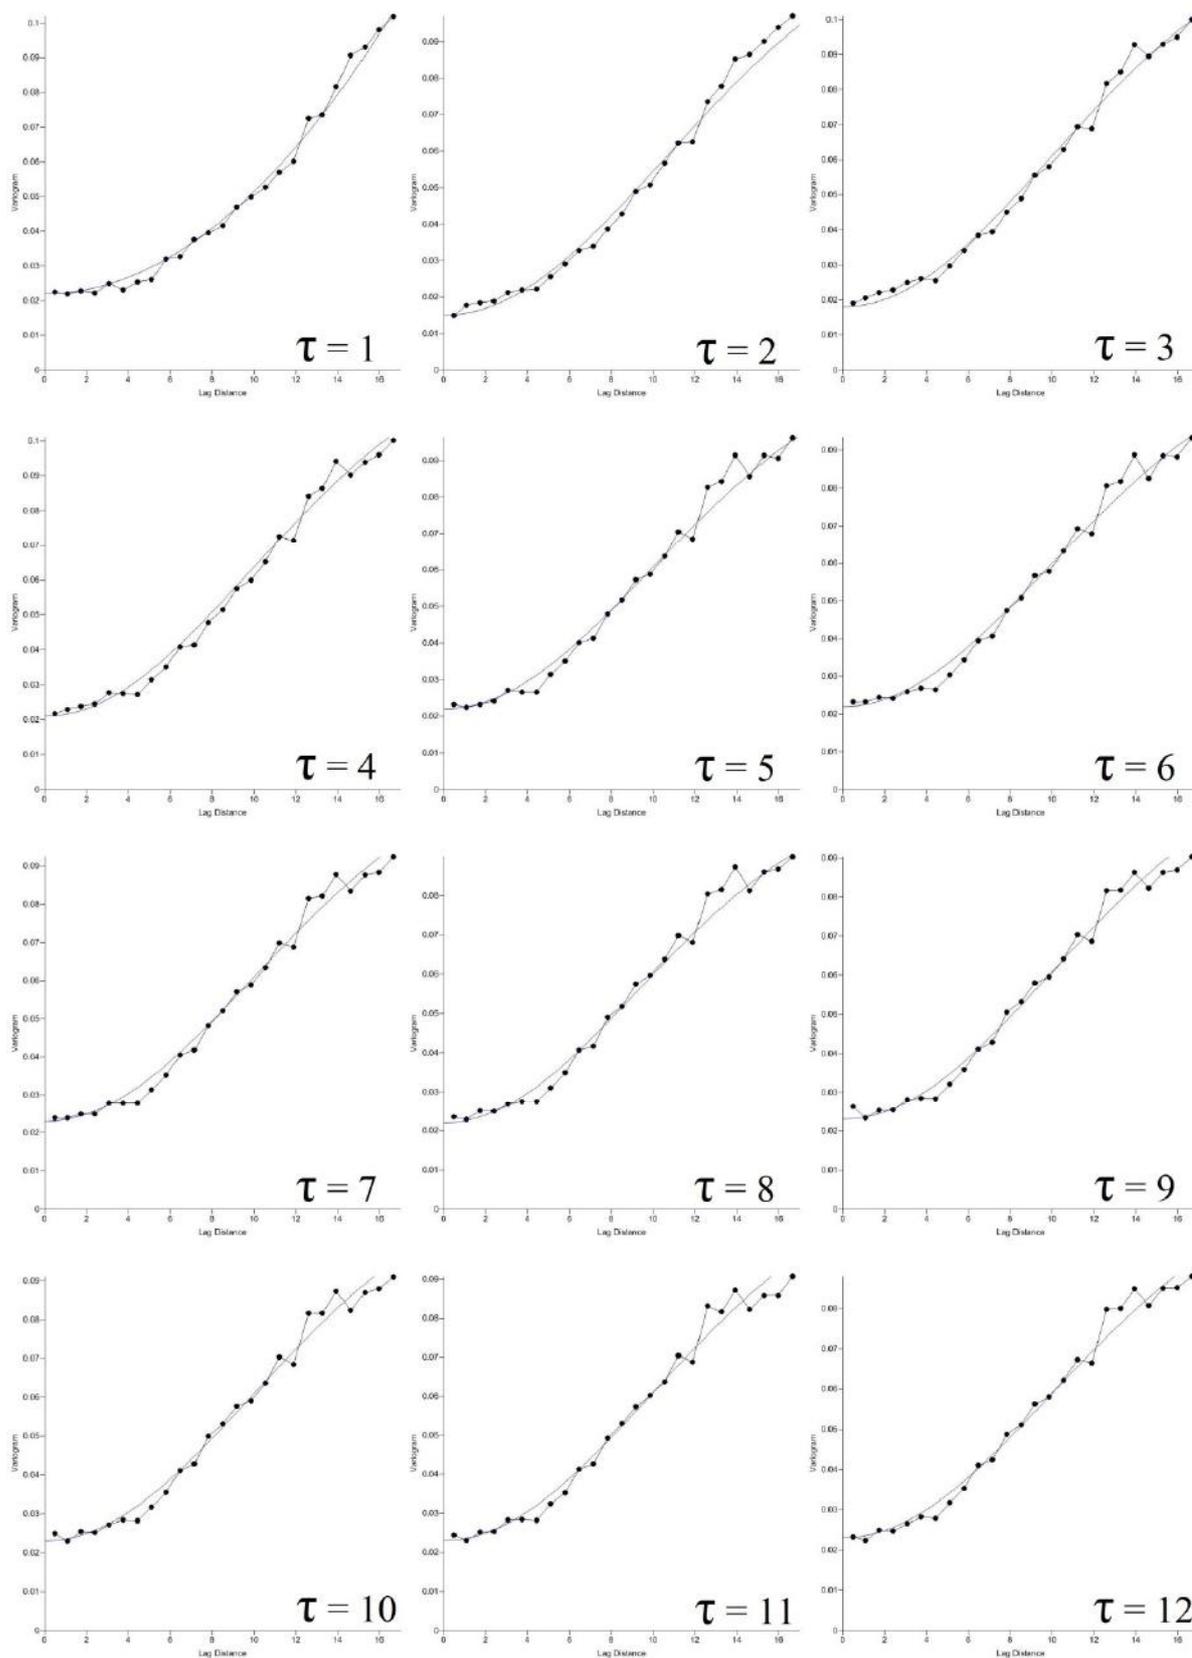


Figura 7.6: Continuação.

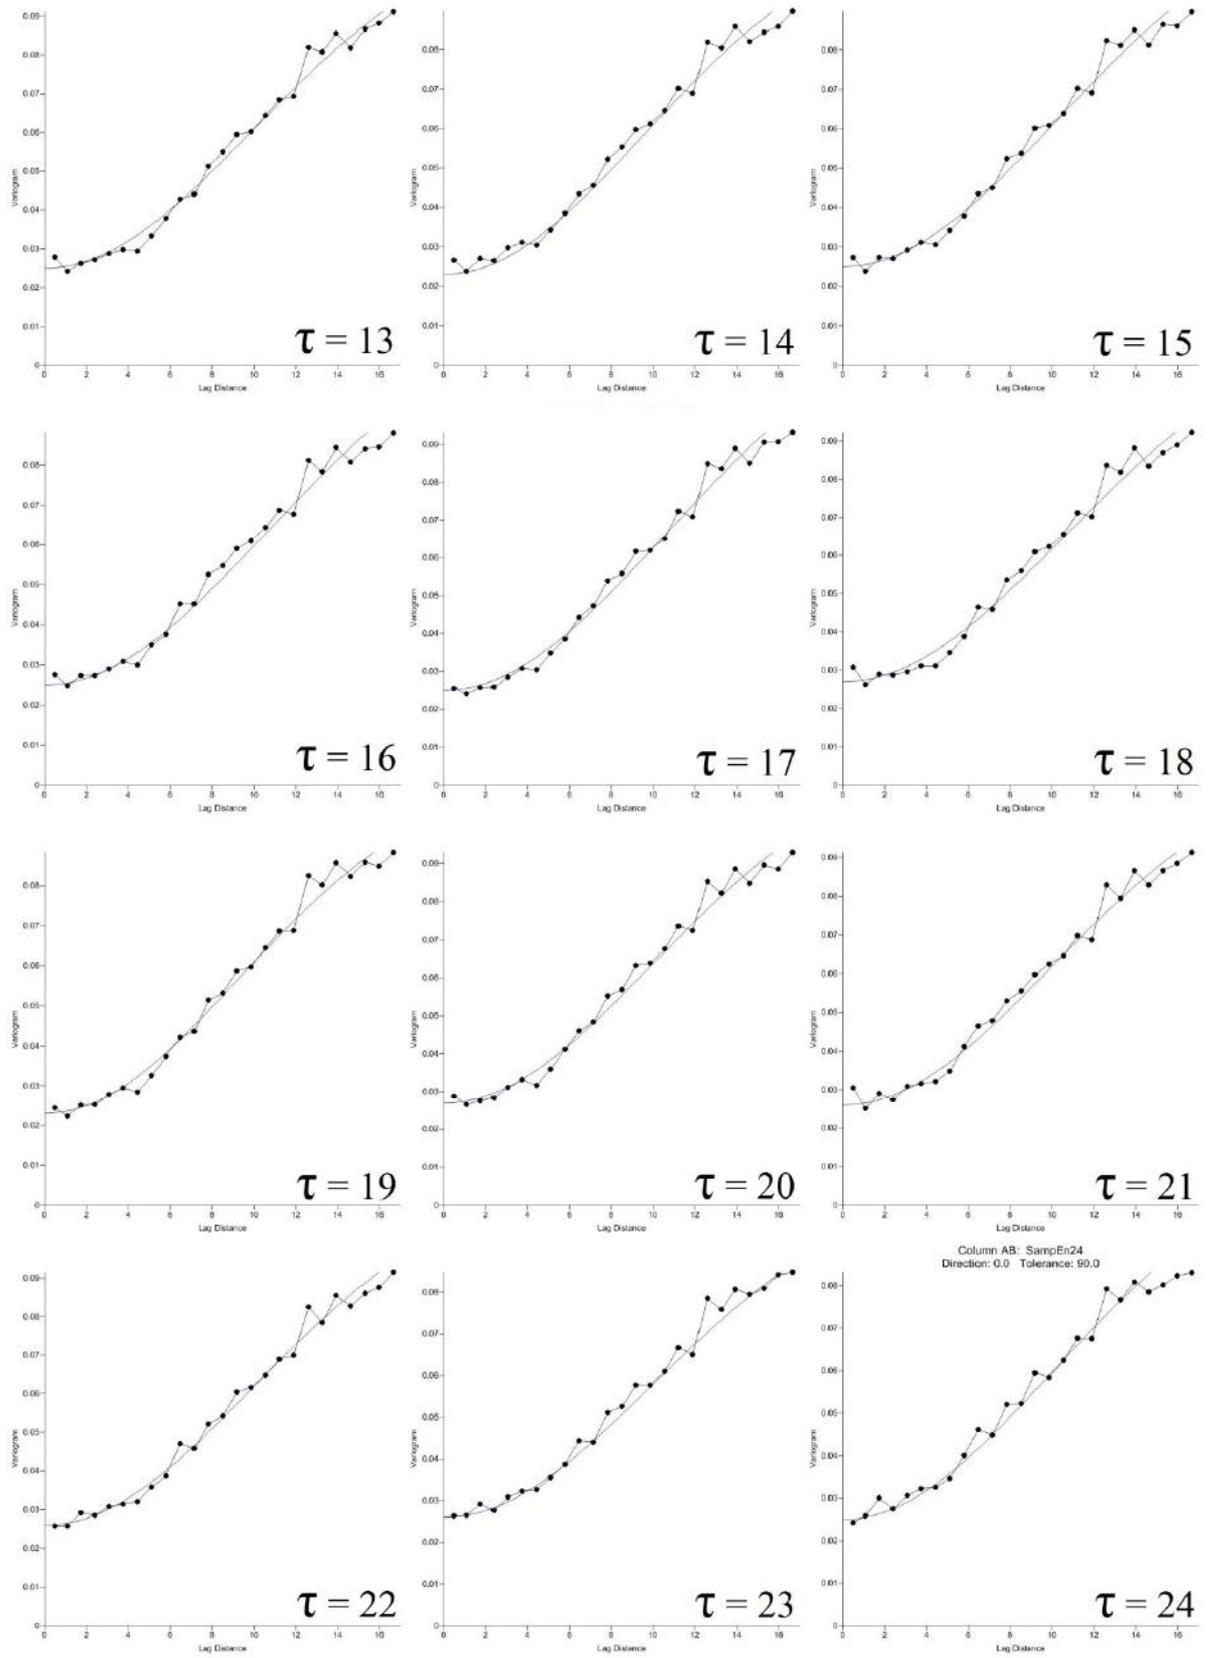


Figura 7.6: Continuação.

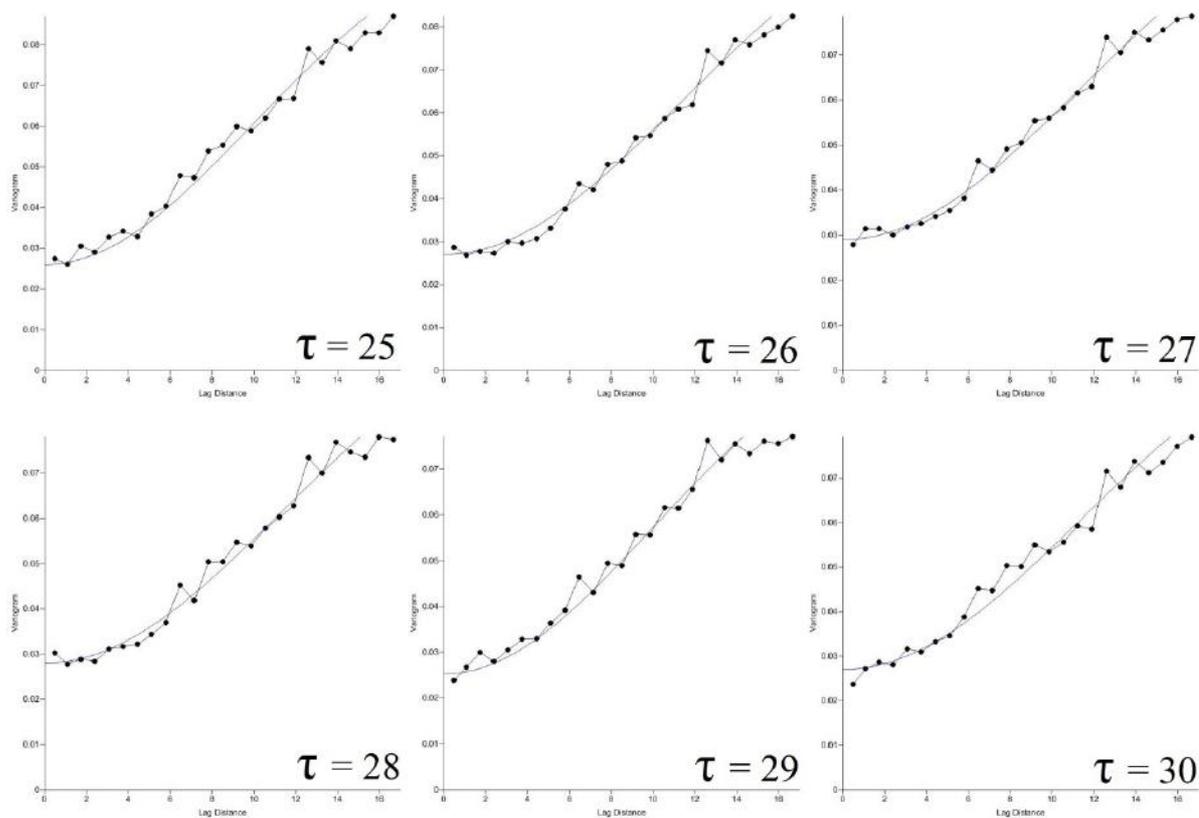


Figura 7.7: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de umidade relativa média diária do ar no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).

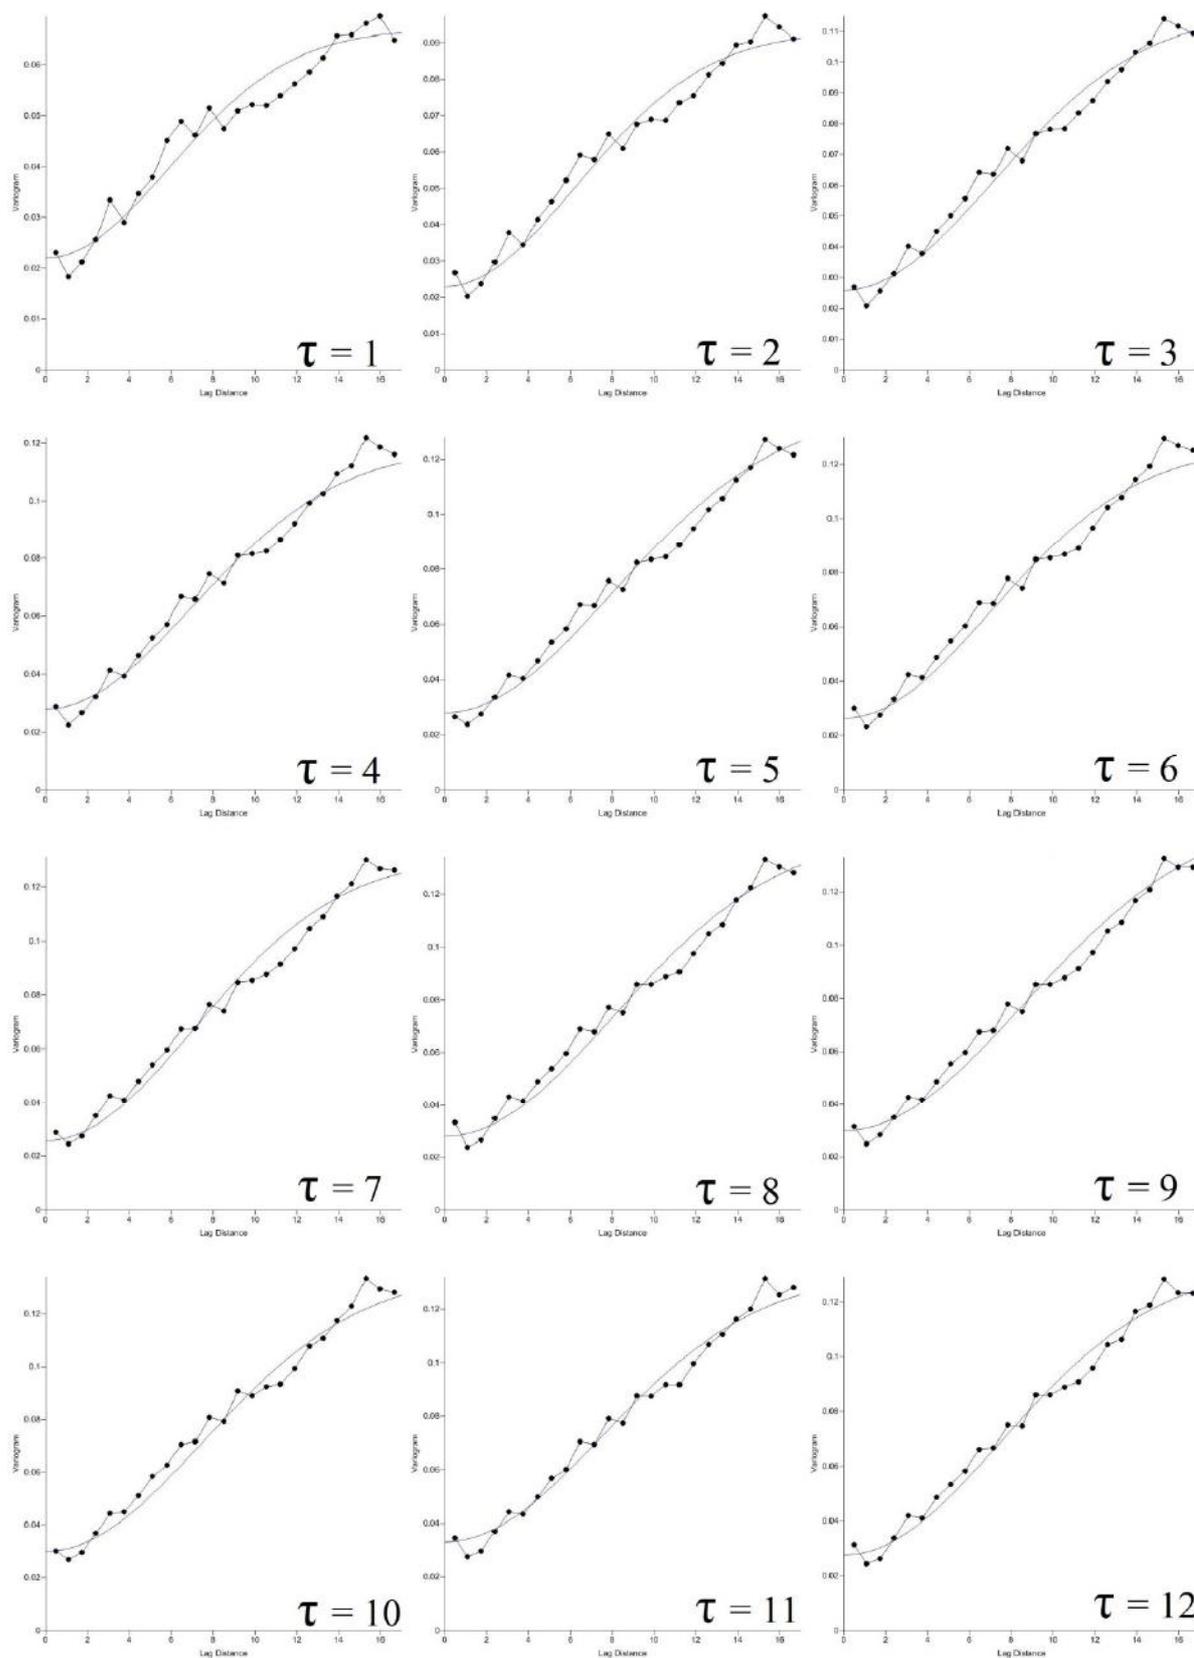


Figura 7.7: Continuação.

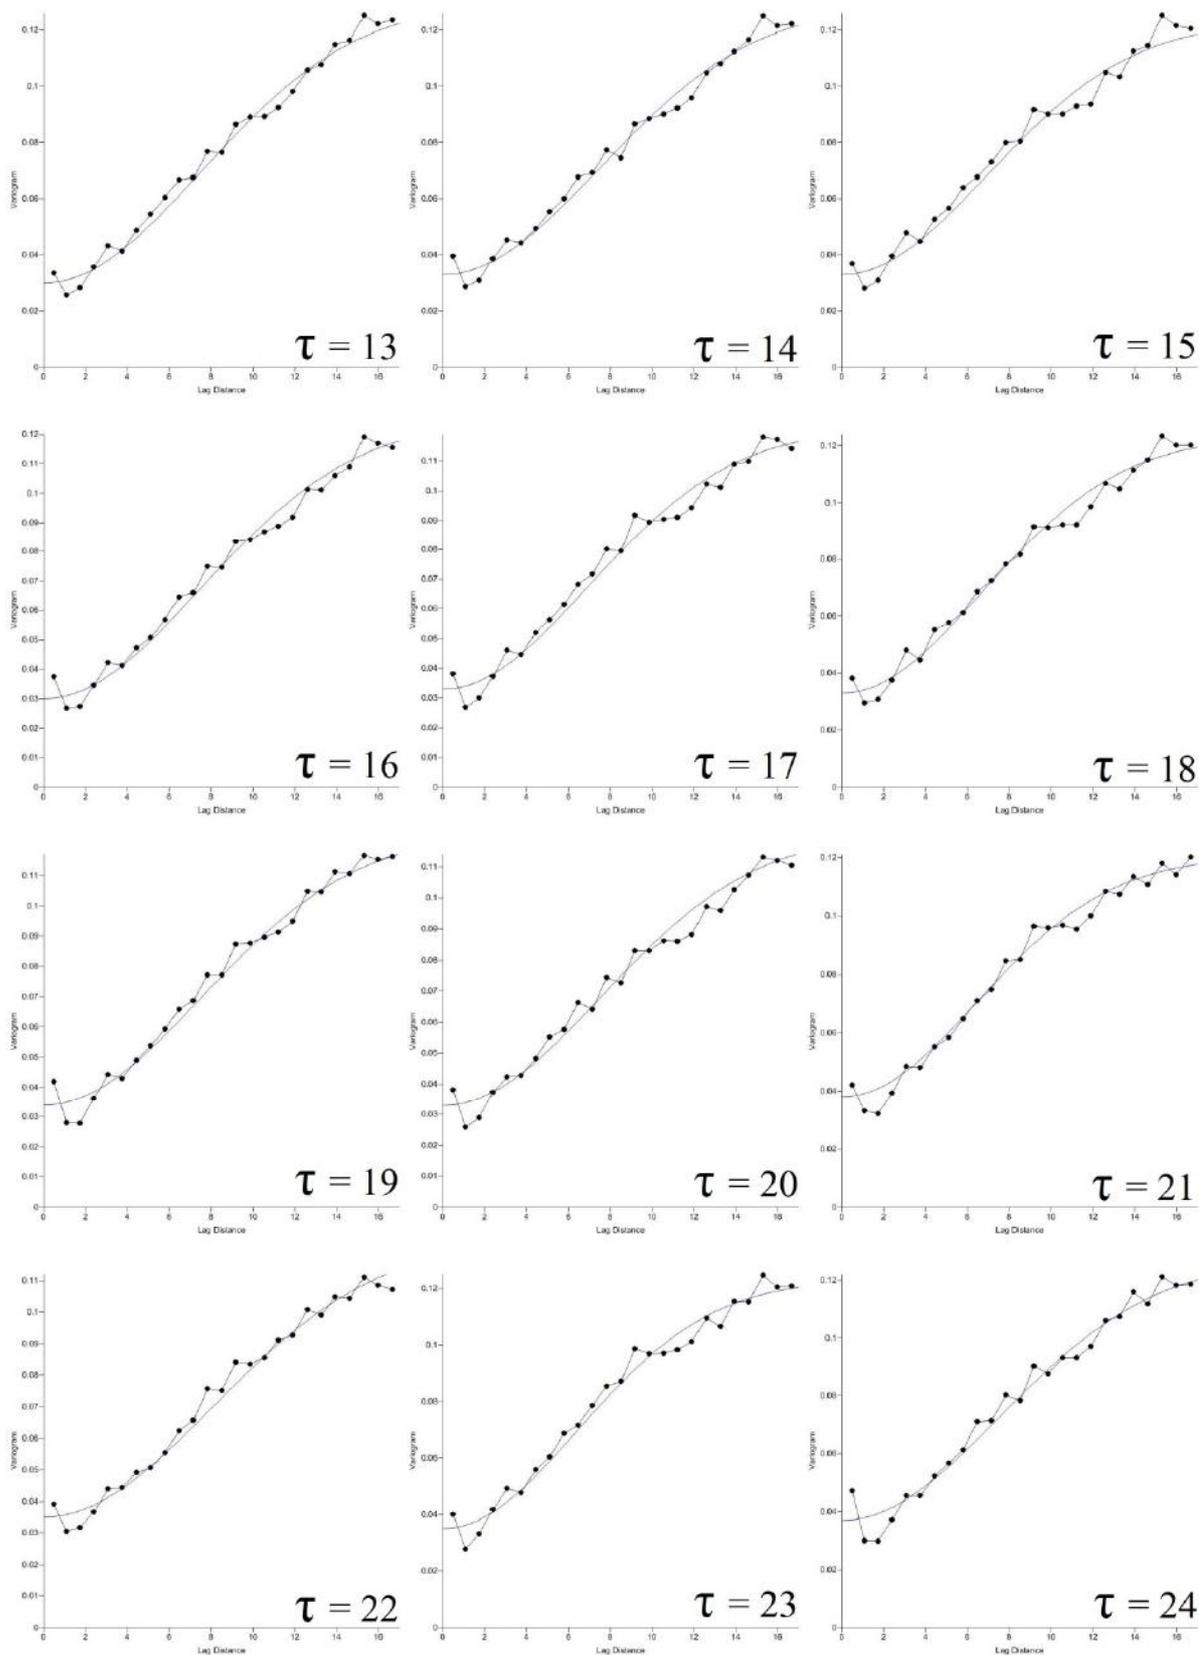


Figura 7.7: Continuação.

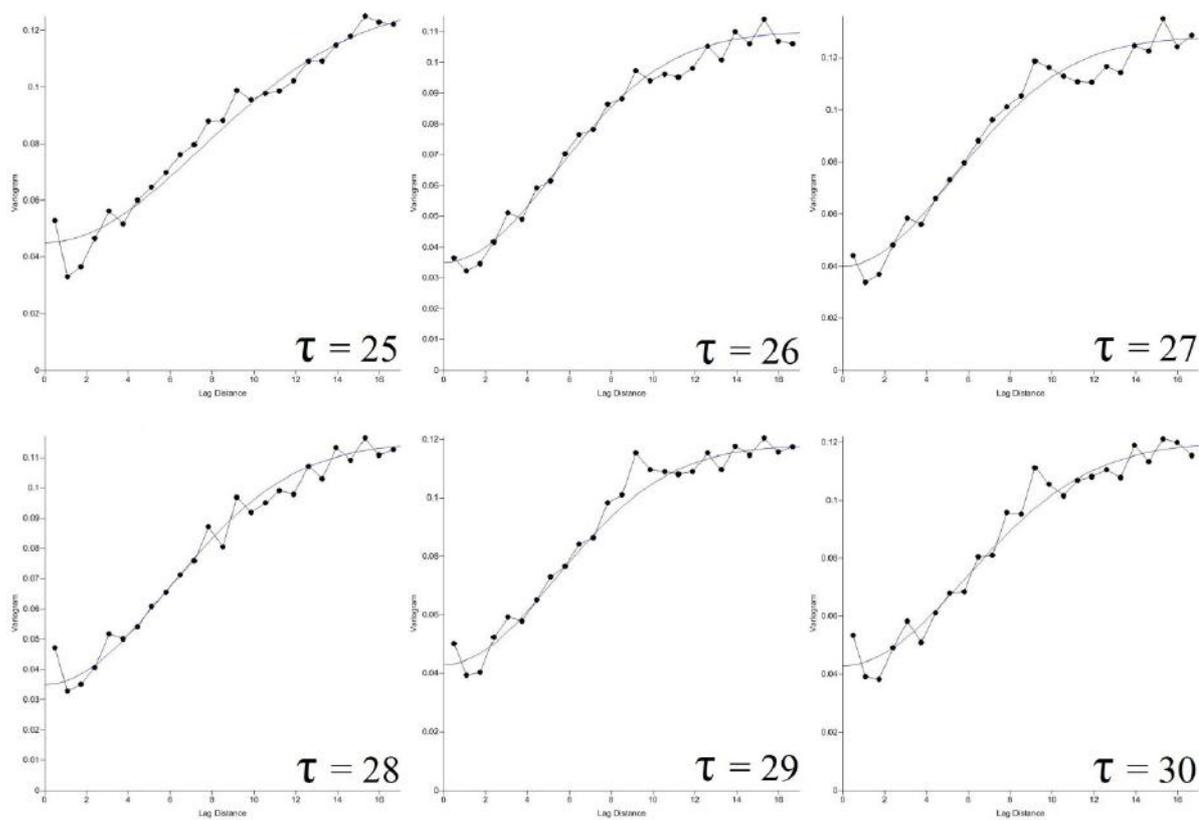


Figura 7.8: Variogramas dos coeficiente de entropia (Sample Entropy) das séries de velocidade média diária do vento no Brasil, no período de 1990 a 2012, ($\tau = 1, 2, \dots, 30$ dias).

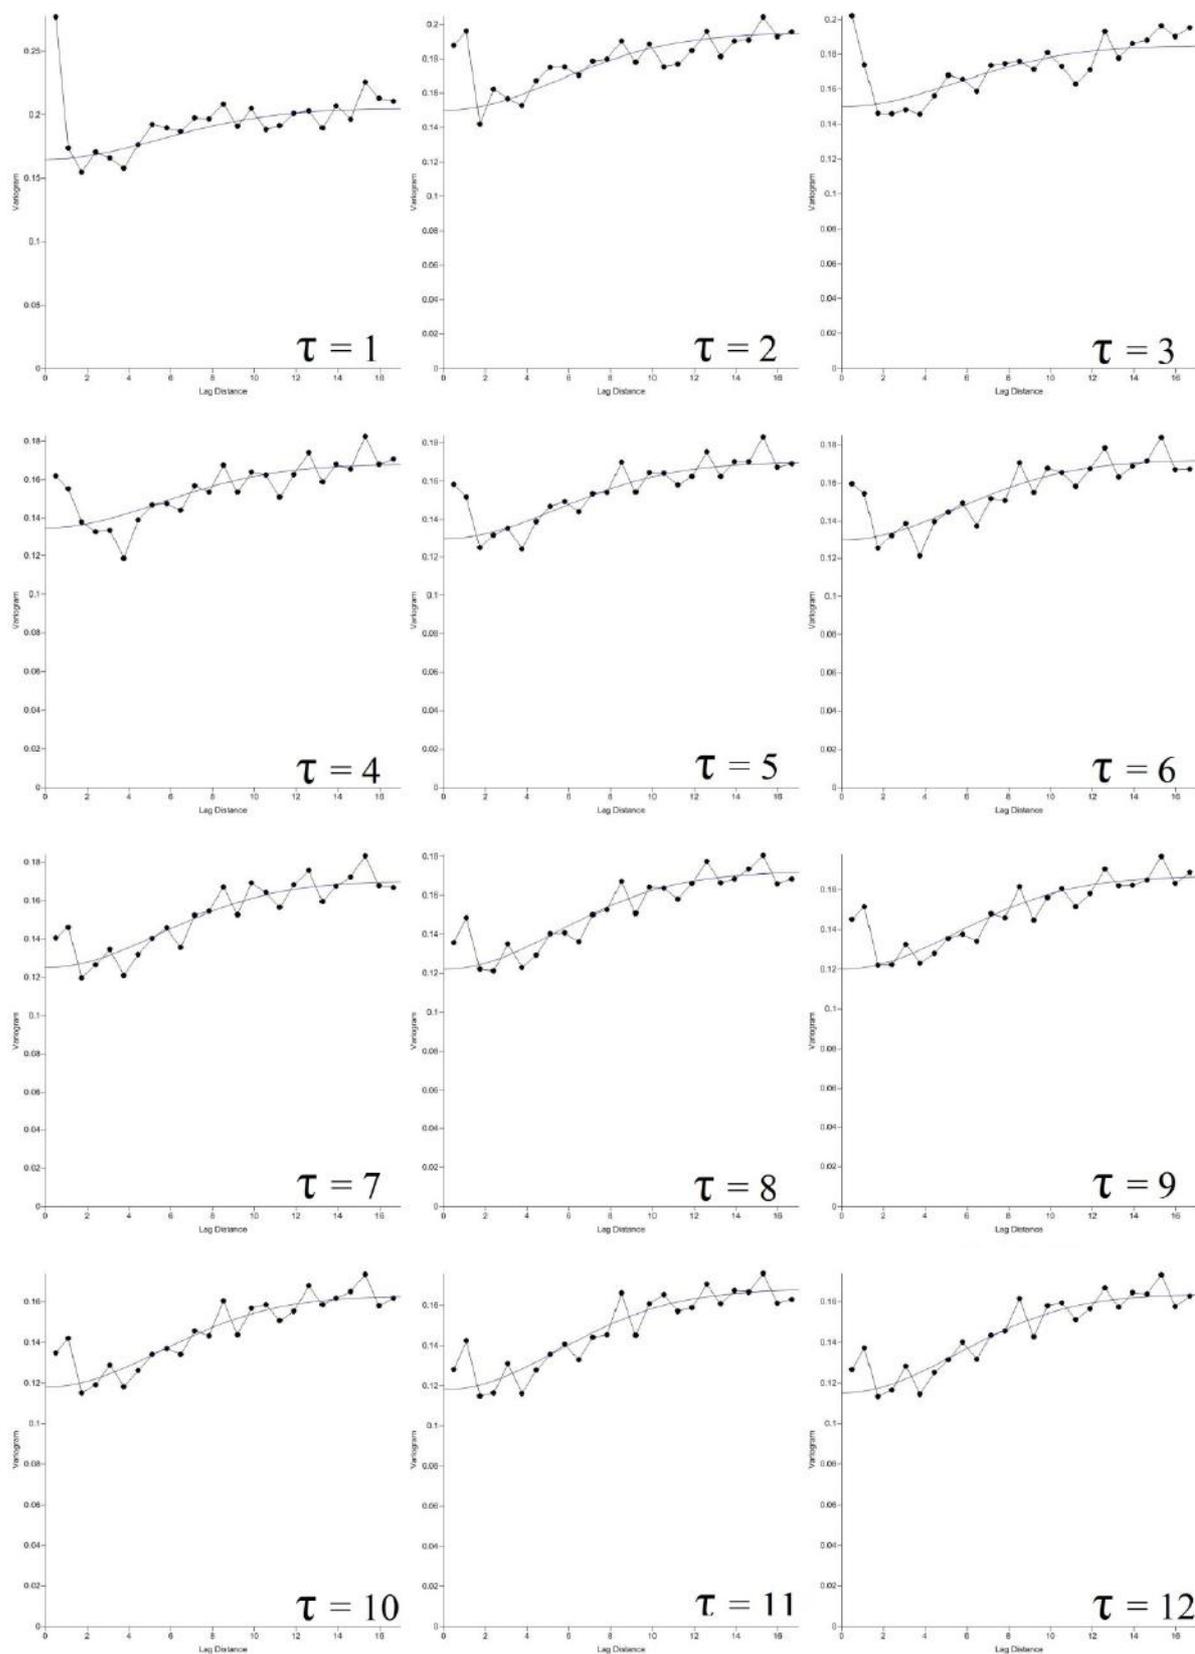


Figura 7.8: Continuação.

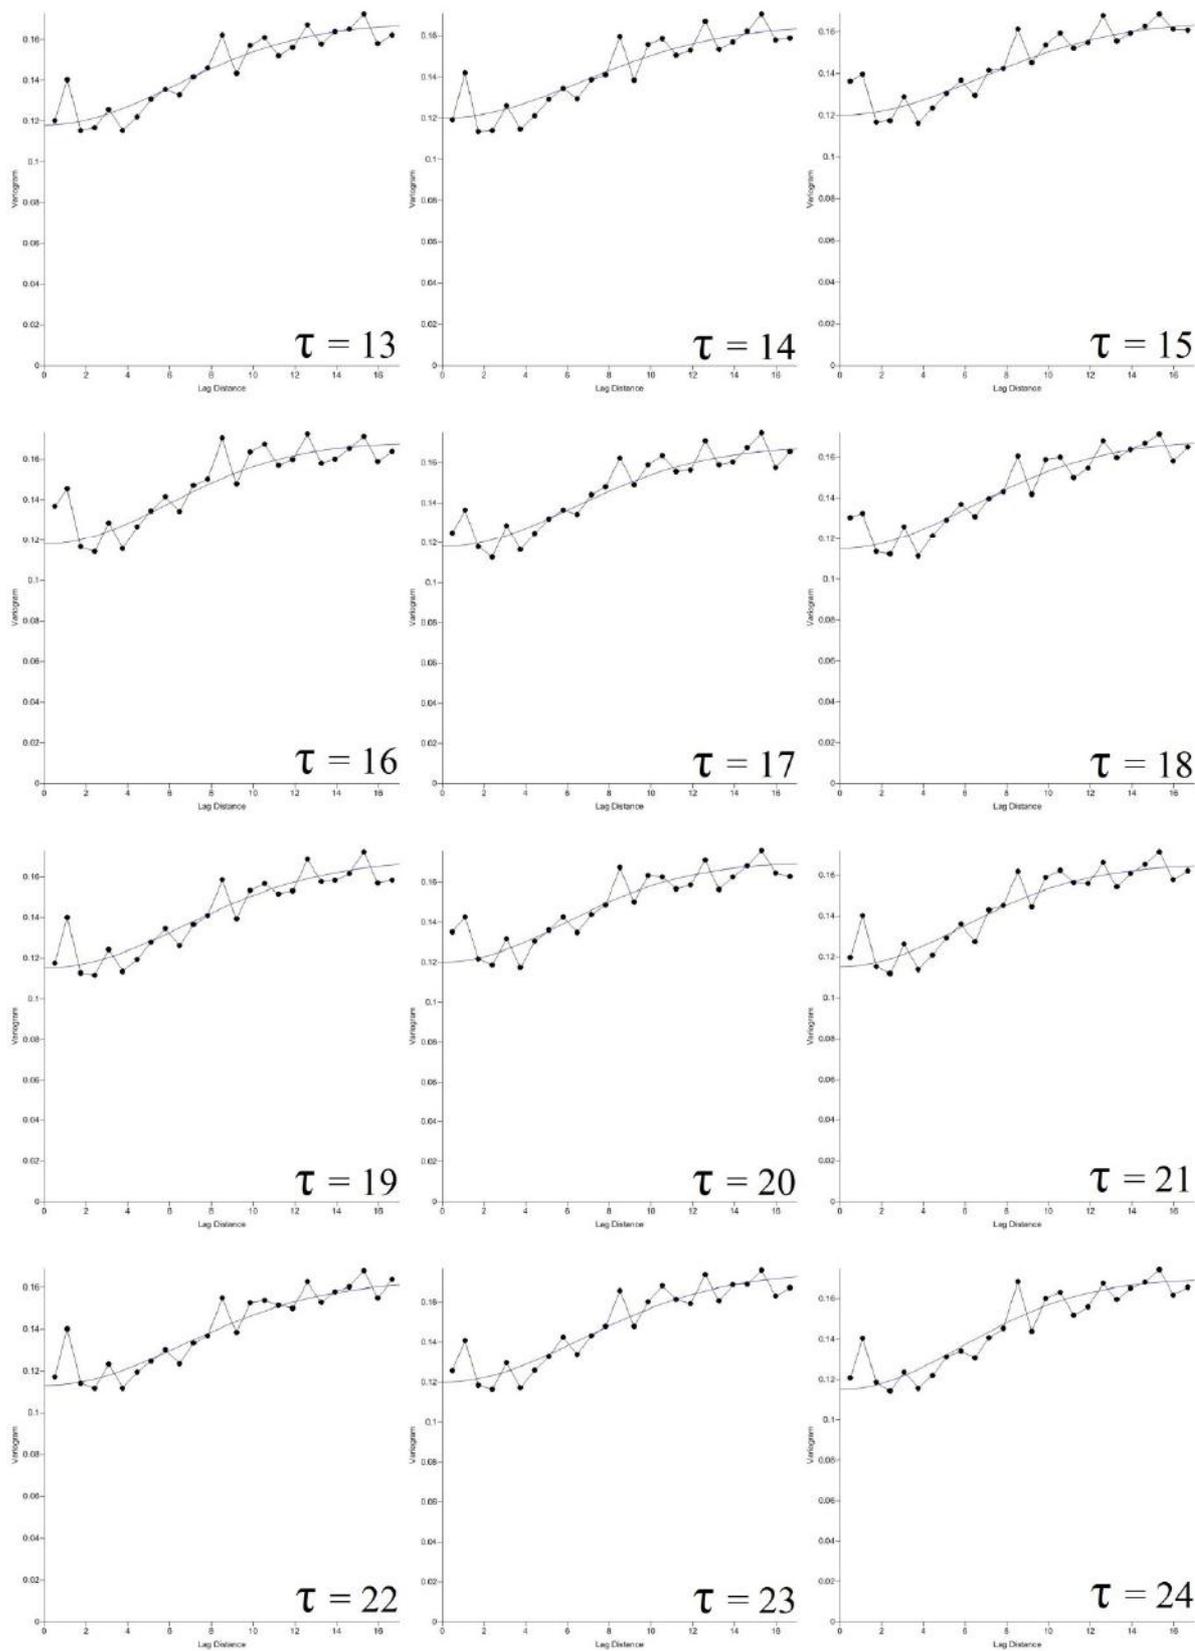


Figura 7.8: Continuação.

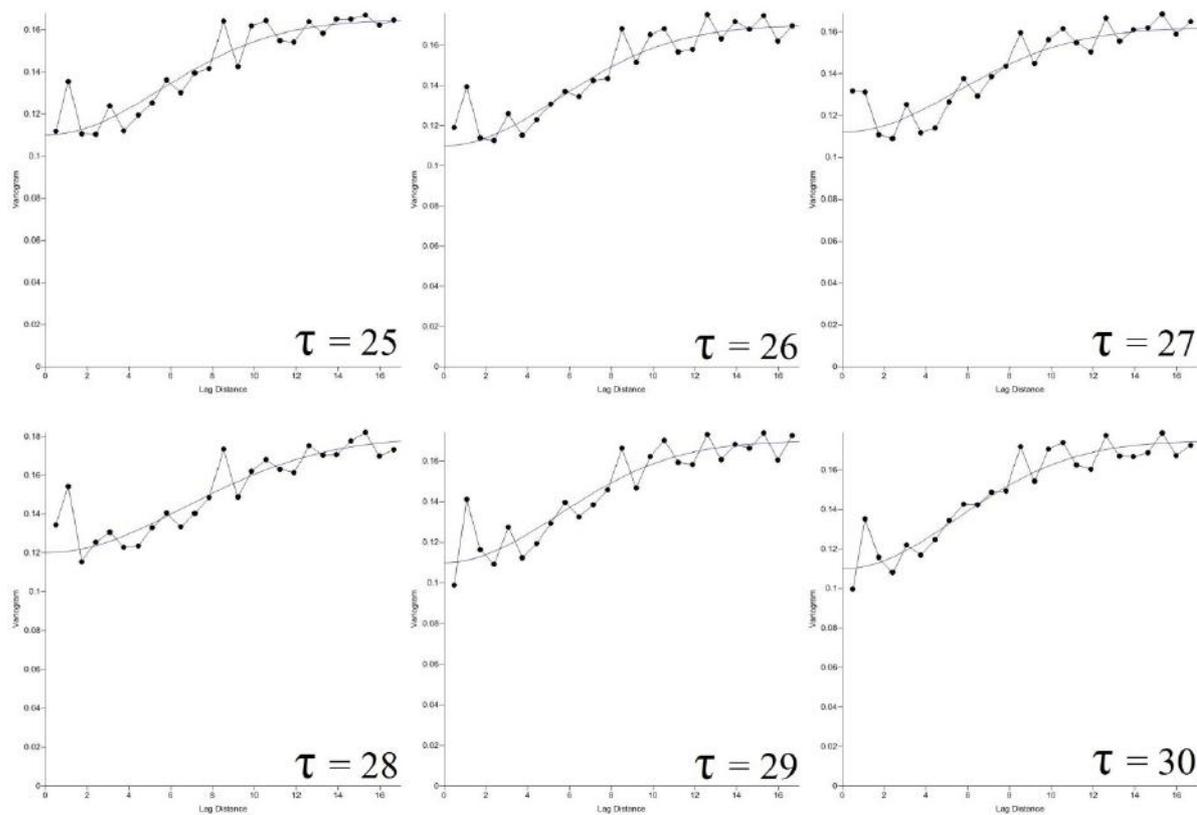


Figura 7.9: Variograma dos expoentes DFA das séries de temperatura média diária do ar (A), amplitude térmica diária do ar (B), temperatura máxima diária do ar (C), temperatura mínima diária do ar (D), umidade relativa média diária do ar (E) e velocidade média diária do vento (F), no Brasil, no período de 1990 a 2012.

