**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Caracterização espacial e temporal de parâmetros climáticos no estado de
Mato Grosso**

Bruno Gherardi

Dissertação apresentada para a obtenção do título de Mestre
em Agronomia. Área de concentração: Fitotecnia

**Piracicaba
2008**

Bruno Gherardi
Engenheiro Agrônomo

Caracterização espacial e temporal de parâmetros climáticos no estado de Mato Grosso

Orientador:

Prof. Dr. **DURVAL DOURADO NETO**

Dissertação apresentada para a obtenção do título de Mestre
em Agronomia. Área de concentração: Fitotecnia

Piracicaba
2008

**Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA E DOCUMENTAÇÃO - ESALQ/USP**

Gherardi, Bruno

Caracterização espacial e temporal de parâmetros climáticos no estado de Mato Grosso / Bruno Gherardi. - - Piracicaba, 2008.
120 p. : il.

Dissertação (Mestrado) - - Escola Superior de Agricultura Luiz de Queiroz, 2008.
Bibliografia.

1. Análise de séries temporais 2. Balanço hídrico 3. Climatologia - Mato Grosso 4. Geoestatística 5. Precipitação 6. Temperatura I. Título

CDD 551.6

G415c

“Permitida a cópia total ou parcial deste documento, desde que citada a fonte – O autor”

Key words

1. Temporal series analysis 2. Water balance 3. Climatology 4. Geostatistic 5. Rainfall 6. Temperature I. Title

À meu pai Plínio Gherardi

Dedico

Ofereço este trabalho ao meu pai, que me deu suporte e acompanhou com tamanha ênfase minha trajetória.

AGRADECIMENTOS

Agradeço ao prof. Dr. Pablo Vidal-Torrado com quem iniciei meus trabalhos acadêmicos.

Agradeço ao Prof. Dr. Miguel Cooper com quem desenvolvi diversos trabalhos na graduação, importantes para essa dissertação.

Agradeço ao Prof. Dr. Gerd Sparovek por todo apoio dado em trabalhos que desenvolvi.

Agradeço ao Prof. Dr. Paulo César Sentelhas pelas dicas dadas para o desenvolvimento do modelo.

Agradeço ao Prof. Dr. Durval Dourado Neto pela oportunidade em ser seu orientado.

Agradeço Luiz Eduardo Oliveira de Faria pela parceria nas etapas que vencemos dia após dias.

Agradeço Winston Quirino França que muito ajudou na manipulação do banco de dados gerado nesta dissertação de mestrado.

Agradeço o Instituto Nacional de Meteorologia (INMET) e à Agência Nacional de Águas (ANA) que concederam os dados necessários para o desenvolvimento deste mestrado.

Agradeço tudo o que a Escola Superior de Agricultura “Luiz de Queiroz” proporcionou para a minha formação.

SUMÁRIO

RESUMO.....	8
ABSTRACT.....	9
LISTA DE FIGURAS.....	10
LISTA DE TABELAS.....	17
1 INTRODUÇÃO.....	18
2 REVISÃO BIBLIOGRÁFICA	21
2.1 Geradores de série sintética	21
2.1.1 Precipitação.....	22
2.1.2 Temperatura.....	23
2.1.3 Validação dos modelos	24
2.2 Geoestatística	25
2.2.1 Solo	27
2.2.2 Temperatura	29
2.2.3 Precipitação.....	29
2.3 Correlação de parâmetros climáticos com as coordenadas e altitude	30
2.3.1 Temperatura	31
2.3.2 Precipitação.....	32
2.4 Balanço hídrico	33
2.4.1 Pedotransferência para estimativa da capacidade de armazenamento de água no solo ..	34
3 MATERIAL E MÉTODOS	36
3.1 Obtenção das séries históricas das variáveis climáticas	36
3.2 Regressão linear multivariada.....	37
3.3 Criação de séries sintéticas	38
3.3.1 Temperatura	38
3.3.2 Precipitação.....	39
3.4 Validação do modelo	40
3.5 Pedotransferência.....	43
3.6 Balanço hídrico	44
4 RESULTADOS E DISCUSSÃO.....	45

4.1	Regressões lineares múltiplas para os dados diários de precipitação e temperatura	45
4.2	Geradores de série sintética: validação	47
4.2.1	Validação de dados diários	47
4.2.2	Validação de dados mensais	77
4.3	Determinação da capacidade de armazenamento de água (CAD).....	95
4.4	Balanço hídrico normal mensal	101
4.5	Mapas anuais.....	107
5. CONCLUSÕES.....		111
REFERÊNCIAS.....		112

RESUMO

Caracterização espacial e temporal de parâmetros climáticos no estado de Mato Grosso

As condições climáticas de determinada região são de importância estratégica para o planejamento agrícola. No entanto, é comum localidades distantes de alguma estação meteorológica. O presente mestrado teve o intuito de propor um modelo para estimar valores de temperatura média diária e precipitação diária em localidades sem informação meteorológica. Os dados climáticos foram obtidos do Instituto Nacional de Meteorologia Agrícola (INMET) e da Agência Nacional de Águas (ANA). Estimaram-se equações para dados diários através da regressão linear múltiplas entre as variáveis temperatura média (T_m) versus altitude, latitude e longitude, desvio padrão da temperatura (σ_T) versus altitude, latitude e longitude, precipitação média (P_m) versus altitude, latitude e longitude, Precipitação mínima (P_{min}) versus altitude, latitude e longitude, precipitação máxima (P_{max}) versus altitude, latitude e longitude, desvio padrão da chuva (σ_P) versus altitude, latitude e longitude, probabilidade de não chover (η_P) versus altitude, latitude e longitude, correlação da temperatura ρ_T) e precipitação ρ_P) com o dia anterior versus altitude, latitude e longitude para cada dia do ano e verificou-se a significância a 5% de probabilidade. Dessa forma, qualquer localidade passou a ter os parâmetros necessários para a gerar séries sintéticas, assumindo o processo multivariado contínuo. Para a criação da série sintética de temperatura usou-se T_m , σ_T , ρ_T , os parâmetros usados na criação da série de precipitação foram P_{min} , P_{max} , P_m , η_P e ρ_P . Foram geradas séries de 100 anos em 507 localidades para Temperatura média diária e mensal, além de Precipitação média diária e mensal. A capacidade de armazenamento de água (CAD) foi estimada em todas as localidades através de modelos de pedotransferência. Os teores de argila, silte, areia e matéria orgânica do solo usados na pedotransferência foram obtidos do levantamento de solo RADAM e interpolados através da geoestatística. Em todas as localidades foi feito o balanço hídrico pelo método de Thornthwaite com os respectivos valores estimados de temperatura e precipitação, além da CAD específica da localidade. A validação do modelo gerador de séries sintéticas foi feita utilizando índices de correlação entre valores observados e estimados. Usou-se a ERP (erro relativo padrão), o coeficiente de correlação linear (r^2), o índice de concordância (d) e o produto entre o coeficiente de correlação e o índice de concordância, chamado de índice de confiança (c). Obteve-se índices de confiança baixos para a estimativa de temperatura média diária e muito baixos para a precipitação média diária. No entanto, o modelo teve bom desempenho para dados mensais, obtendo índices boa correlação linear e concordância para temperatura e precipitação.

Palavras-chave: Correlação; Coordenadas; Altitude; Temperatura; Precipitação; Balanço hídrico

ABSTRACT

Spacial and temporal climatic parameter characterization in the State of Mato Grosso

The climatic conditions of any region could be of the extreme importance to the strategic analysis of agricultural planning. However, it's common fields that are far away from any meteorological station. This mastership proposes a model to estimate values of daily temperature and rainfall. The climatic data was collected from National Meteorological Agriculture Institute (INMET) and from National Water Agency (ANA). The equation made with linear multiple regression for daily data among the parameters average of temperature (T_m) versus altitude, latitude and longitude, standard deviation of temperature (σ_T) versus altitude, latitude and longitude, average of rainfall (P_m) versus altitude, latitude and longitude, minimal rainfall (P_{min}) versus altitude, latitude and longitude, maximum rainfall (P_{max}) versus altitude, latitude and longitude, standard deviation of rain (σ_P) versus altitude, latitude and longitude, probability of not rain (η_P) versus altitude, latitude and longitude, correlation of temperature (ρ_T) and precipitation (ρ_P) between two consecutive days versus altitude, latitude and longitude. The analysis of significance was done with 5% of probability. Any location could obtain the parameters to generate synthetic series, using a multivariated continuous process. It was used T_m , σ_T , ρ_T to create the synthetic series of temperature, the parameters used to create de synthetic series of rainfall were P_{min} , P_{max} , P_m , η_P e ρ_P . 100 synthetic series were created in 507 locations for daily and monthly temperature and rainfall. The soil water capacity was estimated for all locations using a pedotransfer model. The percentage of clay, silt, sand and organic matter were obtained on the Soil Survey RADAM and interpolated by geostatistical analysis. All locations had the water balance done by Thornthwaite method with its respective estimated value of temperature and rainfall, using the specific soil water capacity of the location. The model validation of synthetic series generator was done using correlations index between observed and estimated values. Was used the relative pattern error (ERP), linear correlation (r^2), concordance index (d) and the product of the last both index called reliable index (c). The reliable index obtained for daily temperature and rainfall was very low. However, the model had a good efficiency for monthly temperature and rainfall.

Keywords: Correlation; Coordinates; Altitude; Temperature; Rainfall; Water balance

LISTA DE FIGURAS

Figura 1 - Exemplo de semivariograma.....	27
Figura 2 - Mapa das estações meteorológicas fornecidas pelo INMET	36
Figura 3 - Mapa das estações hidrometeorológicas fornecidas pela ANA.....	37
Figura 4 - Mapa das estações meteorológicas estimadas.....	41
Figura 5 - Mapa das estações meteorológicas usadas para a validação do modelo	41
Tabela 1 - Análise do desempenho do modelo com base no índice de confiança	43
Tabela 2 - Índices de validação e classificação (c) do modelo de geração de séries de temperatura média diária	47
Tabela 3 - Índices de validação e classificação (c) do modelo de geração de séries de precipitação média diária.....	48
Tabela 4 - Índices de validação e classificação (c) do modelo de probabilidade diária de não chover	49
Figura 6 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	50
Figura 7 - Distribuição linear da Precipitação média diária observada X estimada -validação do modelo.....	50
Figura 8 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo.....	51
Figura 9 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	51
Figura 10 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	52
Figura 11 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	52
Figura 12 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	53
Figura 13 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	53
Figura 14 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	54

Figura 15 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	54
Figura 16 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	55
Figura 17 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	55
Figura 18 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	56
Figura 19 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	56
Figura 20 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	57
Figura 21 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	57
Figura 22 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	58
Figura 23 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	58
Figura 24 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	59
Figura 25 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	59
Figura 26 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	60
Figura 27 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	61
Figura 28 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	61
Figura 29 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	62

Figura 30 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	63
Figura 31 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	63
Figura 32 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	64
Figura 33 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	65
Figura 34 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	65
Figura 35 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	66
Figura 36 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	66
Figura 37 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	67
Figura 38 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	67
Figura 39 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	68
Figura 40 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	68
Figura 41 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	69
Figura 42 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	69
Figura 43 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	70
Figura 44 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	70

Figura 45 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	71
Figura 46 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	71
Figura 47 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	72
Figura 48 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	72
Figura 49 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	73
Figura 50 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	73
Figura 51 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	74
Figura 52 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	74
Figura 53 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	75
Figura 54 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo.....	75
Figura 55 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo.....	76
Figura 56 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo	76
Tabela 5 - Índices de validação e de classificação (c) do modelo de geração de séries de Precipitação média mensal.....	77
Tabela 6 - Índices de validação e de classificação (c) do modelo de geração de séries de temperatura média mensal	78
Figura 57 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	79

Figura 58 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	79
Figura 59 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	80
Figura 60 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	80
Figura 61 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	81
Figura 62 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	81
Figura 63 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	82
Figura 65 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	83
Figura 66 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	83
Figura 67 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	84
Figura 69 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	85
Figura 70 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	85
Figura 71 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	86
Figura 72 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	86
Figura 73 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	87
Figura 74 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	87

Figura 75 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	88
Figura 76 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	88
Figura 77 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	89
Figura 78 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	89
Figura 79 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	90
Figura 80 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	90
Figura 81 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	91
Figura 82 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	91
Figura 83 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	92
Figura 84 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	92
Figura 85 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	93
Figura 86 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	93
Figura 87 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.....	94
Figura 88 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo.....	94
Figura 89 - Mapa de classes de argila obtido por krigagem	95
Figura 90 - Semivariograma mostrando o modelo usado na krigagem de argila.....	95
Figura 91 - Mapa de classes de silte obtido por krigagem	96

Figura 92 - Semivariograma mostrando o modelo usado na krigagem de silte	96
Figura 94 - Mapa de classes do teor de matéria orgânica obtido por krigagem.....	98
Figura 95 - Semivariograma mostrando o modelo usado na krigagem de argila.....	98
Figura 96- Mapa de classes da capacidade de armazenamento de água (CAD) obtido por pedotransferência.....	99
Figura 97 - Mapa de classes de precipitação mensal estimada.....	101
Figura 98 - Mapa de classes de temperatura média mensal estimada	102
Figura 99 - Mapa de classes de evapotranspiração potencial mensal estimada.....	103
Figura 100 - Mapa de classes de evapotranspiração real mensal estimada.....	104
Figura 101 - Mapa de classes de excedente hídrico mensal estimado	105
Figura 102 - Mapa de classes de deficiência hídrica mensal estimada	106
Figura 103 - Mapa de classes de precipitação anual estimada	107
Figura 104 - Mapa de classes de temperatura média anual estimada	107
Figura 105 - Mapa de classes de evapotranspiração potencial anual estimada.....	108
Figura 106 - Mapa de classes de evapotranspiração real anual estimada.....	108
Figura 107 - Mapa de classes de excedente hídrico anual estimada	109
Figura 108 - Mapa de classes de deficiência hídrica anual estimada	109

LISTA DE TABELAS

Tabela 1 - Análise do desempenho do modelo com base no índice de confiança	43
Tabela 2 - Índices de validação e classificação (c) do modelo de geração de séries de temperatura média diária	47
Tabela 3 - Índices de validação e classificação (c) do modelo de geração de séries de precipitação média diária.....	48
Tabela 4 - Índices de validação e classificação (c) do modelo de probabilidade diária de não chover	49
Tabela 5 - Índices de validação e de classificação (c) do modelo de geração de séries de Precipitação média mensal.....	77
Tabela 6 - Índices de validação e de classificação (c) do modelo de geração de séries de temperatura média mensal	78

1 INTRODUÇÃO

O mundo vive uma crise energética, sendo a demanda por combustíveis e alimentos gigantesca. Há uma série de discussões mostrando a necessidade em substituir combustíveis fósseis por biocombustíveis. Toda a demanda energética mundial é suprida, em grande parte, por carvão mineral e petróleo, resultado da assimilação de energia solar incidida na superfície terrestre há milhões de anos atrás. Resta saber se existe a possibilidade de substituição dessa demanda por energias renováveis, não comprometendo a produção de alimentos. Para conseguir planejar essa substituição da fonte energética, priorizando fontes renováveis, é necessário mapear a capacidade de assimilação de energia solar em toda a superfície do planeta.

A capacidade de assimilação energética está diretamente relacionada com o balanço fotossintético do ecossistema que habita essa superfície. Plantas podem investir em biomassa para a parte aérea, incluindo folhas e caule, e para as raízes. Quanto maior for o investimento em superfície foliar, espera-se uma maior captação de luz e conversão da energia luminosa em química, proporcionando altas taxas de crescimento e maiores ganhos de carbono (GRIME; HUNT, 1975). No entanto, um investimento maior em tecidos não fotossintéticos, como tecidos de sustentação e raízes, aumenta a taxa de respiração, contribuindo para um menor balanço de carbono. Além das características morfológicas, a fisiológica da planta também é responsável pela manutenção de um ganho positivo de carbono (LAMBERS; PONS, 1998). Em plantas com elevada eficiência fotossintética, isto é, com uma alta conversão de energia luminosa em química, mais carboidratos de valor energético serão sintetizados (LARCHER, 1986).

Para estimar a capacidade de produção de energia, seja em forma de combustíveis ou alimentos, é necessário estudar a capacidade fotossintética do local. Para isso, é importante conhecer os parâmetros primários usados em modelos de estimativa da produtividade potencial. A temperatura, a precipitação e a capacidade de armazenamento de água do solo são parâmetros primários para a determinação do potencial produtivo de determinada espécie. É a partir desses parâmetros que se pode prever o comportamento de uma cultura agrícola ao longo de seu ciclo produtivo. Alfonsi e Camargo (1989) indicaram que nas áreas intertropicais, a disponibilidade hídrica é o fator determinante do desenvolvimento e produtividade dos vegetais. É através desses parâmetros que se faz a escolha do momento ideal para a iniciar o ciclo, de forma a torná-lo mais produtivo. Fancelli e Lima (1983) e Moricochi, (1989) mencionaram que tecnologias simples e essenciais, como semeadura na época adequada, cultivares adaptados às condições regionais, uso

de sementes fiscalizadas, densidade de semeadura apropriada, uso correto de fertilizantes, podem ser aplicadas para proporcionar condições que permitam à cultura manifestar todo seu potencial produtivo.

Sabendo-se a seqüência diária de temperatura ao longo do crescimento de uma cultura, sabe-se a evapotranspiração diária dessa cultura (THORNTHWAITE; MATHER, 1955), podendo-se estimar a quantidade de matéria seca a ser produzida, além da distribuição dessa matéria para órgãos da planta de interesse comercial. A precipitação irá identificar se a intensidade da evapotranspiração está atuando em seu potencial, ou se está deplecionada devido à falta de água (THORNTHWAITE; MATHER, 1957). Conhecendo-se o desempenho dessas duas variáveis, associadas ao comportamento do solo em relação à CAD (Capacidade de Armazenamento de água), pode-se prever riscos de veranico, deficiência hídrica, excedente hídrico, armazenamento de água no solo e, portanto, o potencial produtivo, determinado pelo potencial fotossintético, o que reflete na assimilação potencial de energia solar da região.

Os parâmetros temperatura e precipitação são coletados em estações meteorológicas, que muitas vezes não estão presentes na região a ser estudada. Uma das dificuldades do planejamento agrícola está na obtenção de parâmetros climáticos necessários para a tomada de decisões. Geralmente, existem grandes áreas sem informação meteorológica, havendo a necessidade de usar valores do entorno para estimar parâmetros. Na literatura existente sobre o assunto são apresentados vários modelos para geração de séries sintéticas de dados climáticos, sendo, dentre estes, os de uso mais generalizado o CLIGEN (*Climate Generator*), o WGEN (*Weather Generator*), o WXGEN (componente do modelo EPIC - *Erosion/Productivity Impact Calculator*), o WEATHERMAN e o USCLIMATE (BAENA, 2004).

Poucos trabalhos de pesquisa têm sido direcionados para a obtenção de modelos que possibilitem a geração de dados climáticos considerando as condições edafoclimáticas Brasileiras. Normalmente as pesquisas se limitam ao estudo de freqüência das séries históricas disponíveis ou a ajustes de funções de densidade de probabilidade a estes dados (BAENA, 2004). Alguns autores tem se esforçado para conseguir estimativas climáticas usando modelos geoestatísticos, no entanto, a exigência em processamento necessária para obtenção de um modelo por dia do ano não justifica o esforço, tendo em vista os resultados obtidos na literatura. Esses modelos são bastante desenvolvidos para caracterizações edáficas, sendo essa técnica bastante empregada no Brasil.

Este trabalho tem como intuito propor um modelo para a interpolação de parâmetros climáticos que obteve 100 seqüências anuais diferentes de valores diários de temperatura e precipitação para 507 localidades no Estado do Mato Grosso. Além disso, todas as séries sintéticas tiveram seu balanço hídrico normal mensal calculado pelo método de Thornthwaite; Mather (1955) a partir da CAD respectiva do solo, obtida por pedotransferência, na coordenada da estação meteorológica criada. Os parâmetros usados na pedotransferência foram obtidos através de modelos geoestatísticos.

2 REVISÃO BIBLIOGRÁFICA

2.1 Geradores de série sintética

Os geradores climáticos são modelos de simulação matemática que estimam a ocorrência de variáveis climáticas e tem por objetivo a geração de um conjunto de valores numéricos, denominado série sintética, com as mesmas características estatísticas da série histórica.

São largamente utilizados em trabalhos de pesquisa e extensão no mundo inteiro. Essas ferramentas têm demonstrado ser de grande utilidade em muitas áreas, pois permitem, a um baixo custo, a obtenção de informações a respeito do clima local, permitindo, através de simulações, avaliar a sua influência tanto nos processos naturais como nos decorrentes da intervenção humana. Os dados climáticos simulados por estes geradores, dentre outras aplicações, são utilizados como dados de entrada em muitos modelos hidrológicos e de predição do processo erosivo. De uma forma geral, as principais variáveis estudadas são: precipitação, radiação solar, temperatura, umidade e vento (BAENA, 2004).

Segundo Zanetti (2003) a utilização de geradores climáticos na construção de cenários para a avaliação do impacto associado a mudanças climáticas é muito útil devido ao fato de que séries observadas de dados do clima para condições futuras não existem. Isso permite sua aplicação em modelos de predição, que utilizam, ao invés de dados observados, dados que representam uma projeção futura do comportamento climático da localidade de interesse.

Geradores climáticos também fornecem um caminho atrativo para a obtenção de parâmetros de entrada para a modelagem de ecossistemas. Friend (1997) obtiveram as principais variáveis de entrada para um modelo utilizado na análise da dinâmica de ecossistemas terrestres a partir de séries sintéticas. Esse recurso também foi usado por Kittel (1995) na construção de um banco de dados bioclimáticos, o que permitiu a análise da sensibilidade de um ecossistema às mudanças climáticas. De forma similar, He (1997) usou séries simuladas em estudos relacionados aos efeitos do aumento da retirada de água para irrigação de áreas agrícolas no comportamento dos Grandes Lagos dos no Nordeste dos Estados Unidos. Pickering e Stedinger (1988) usaram séries sintéticas para investigar os efeitos da variabilidade do clima na poluição de sistemas hidrológicos. Stern e Dennett (1982) obtiveram as estatísticas climáticas relevantes para o desenvolvimento de um programa de apoio à agricultura a partir de um gerador climático, ao invés de usar os dados de uma curta série de dados observados.

A utilização de geradores climáticos apresenta um grande potencial de uso no Brasil, tendo em vista o reduzido número de localidades que possuem séries climáticas observadas extensas e confiáveis. Estudos realizados para as condições brasileiras, como o de Oliveira (2003), Cecílio (2004) e Amorim (2004), entretanto, mostram que a utilização dos geradores climáticos desenvolvidos no exterior não tem conduzido a resultados satisfatórios, tendo em vista o fato de terem sido desenvolvidos para condições edafoclimáticas muito diferentes das observadas no país.

Virgens Filho (1997) desenvolveu um modelo denominado GEPAC - Gerador Estocástico de Parâmetros Climáticos para geração de dados diários de precipitação, radiação solar, temperaturas máxima e mínima e umidade relativa do ar. Este modelo, aperfeiçoado por Virgens Filho (2001), utiliza as distribuições de probabilidade gama, normal e exponencial negativa para o cálculo das variáveis climáticas, identificando, para cada mês, de acordo com os resultados do teste de aderência de Kolmogorov-Smirnov, qual das três distribuições apresenta o melhor ajuste. A partir dos testes realizados, o autor concluiu que os dados gerados pelo modelo não diferem estatisticamente dos dados observados, podendo, portanto, ser considerada uma ferramenta alternativa em atividades de planejamento agrícola.

2.1.1 Precipitação

O processo de ocorrência da precipitação compreende a separação de dois estados: seco ou chuvoso. Um aspecto chave dos geradores climáticos é a representação da tendência de agrupamento sequencial dos dias chuvosos e secos, chamada de persistência ou correlação serial positiva (autocorrelação), sendo que a cadeia de Markov descreve bem essa tendência (VIANA et al., 2000).

A primeira ordem deste modelo é muito utilizada para determinar a probabilidade de ocorrência ou não de chuvas, considerando o fato de que a probabilidade de ocorrência de precipitação em um dado dia qualquer depende da ocorrência ou não de chuva no dia anterior (NICKS; HARP, 1980; RICHARDSON, 1981; ALMEIDA, 1995; VIRGENS FILHO, 1997).

Oliveira (2003) e Zanetti (2003) desenvolveram um gerador de séries sintéticas de precipitação diária (ClimaBR) baseando-se em registros pluviográficos históricos de onze estações meteorológicas do Estado do Rio de Janeiro. O modelo requer, como dados de entrada, apenas registros pluviométricos diários. A metodologia desenvolvida permite gerar, diariamente, dados de precipitação, incluindo informações como a lâmina precipitada, a duração, a intensidade

máxima instantânea e seu tempo de ocorrência, para os eventos gerados, além do perfil instantâneo dos mesmos. O modelo foi desenvolvido com base na premissa de que para cada dia chuvoso é gerado um único evento de precipitação, estatisticamente equivalente ao somatório dos eventos que ocorreram diariamente na série histórica. O desempenho do modelo foi comparado com os dados observados e com dados obtidos utilizando o CLIGEN, apresentando resultados que mostram a potencialidade de adoção da nova metodologia para a geração de séries sintéticas de precipitação para o Estado do Rio de Janeiro.

Richardson (1982) comparou as distribuições gama, exponencial e exponencial mista e concluiu que todas reproduzem de forma satisfatória os totais mensais e anuais, mas a distribuição exponencial mista forneceu um melhor ajuste do total pluviométrico diário para a maioria das localidades, sendo esta mesma conclusão obtida por Wilks (1999).

Alguns modelos, como o WGEN, CLIGEN e ClimaBR utilizam a distribuição Pearson Tipo III normalizada para a determinação da precipitação total diária para os dias chuvosos. Essa distribuição utiliza como dados de entrada os valores mensais da média, desvio padrão e coeficiente de assimetria da precipitação total diária observada na série histórica, sendo que Oliveira (2003), em estudo realizado para 11 localidades do Estado do Rio de Janeiro, afirma que os modelos CLIGEN e ClimaBR apresentam bom desempenho na estimativa desta variável, com desvios entre os valores observados e gerados variando entre 0 e 8.

2.1.2 Temperatura

Os primeiros modelos de simulação de variáveis climáticas já consideravam a associação existente entre a temperatura e a precipitação. Diversos trabalhos, como os de Jones e Colwick; Threadgill (1972), Larsen e Pense (1982) e Nicks e Harp (1980) usaram, respectivamente, a distribuição normal, curvas senoidais de três parâmetros para gerar séries de temperatura e radiação solar com parâmetros ajustados de acordo com a época do ano e o estado dos dias atual e anterior. O maior problema destes modelos é que os coeficientes de assimetria, as correlações entre as temperaturas e a radiação solar e as auto-correlações são ignoradas.

Richardson (1981) adotou um processo estocástico multivariado contínuo, conforme metodologia proposta por Matalas (1967), para gerar séries de resíduos de temperaturas máxima e mínima e radiação solar, assumindo que os resíduos eram normalmente distribuídos e condicionados apenas à condição do dia atual (chuvosa ou seca).

Este modelo preserva a associação entre as variáveis com base em matrizes de correlação. Uma implementação comum deste algoritmo trata essas matrizes como sendo constantes no tempo e iguais para qualquer localidade (RICHARDSON, 1984). Wilks (1992) afirma que essa consideração é perigosa, particularmente para aqueles elementos altamente dependentes das correlações entre variáveis, como a radiação solar e a temperatura. Usando dados da Austrália, (GUENNI, 1990) constataram que as correlações são dependentes da localidade e da época do ano, sendo verificada também uma pequena dependência entre a temperatura e a condição do dia e que a nebulosidade tem importância expressiva no comportamento da temperatura.

Rajagopalan e Lall (1999) desenvolveram um modelo multivariado com dependência de um dia de defasagem para seis variáveis climáticas. Um vetor para cada variável é obtido da base de dados históricos para cada dia simulado, sendo este condicionado ao dia anterior. O modelo foi aplicado para dados climáticos de uma série de 30 anos para a cidade de Salt Lake City (Estados Unidos) e os resultados foram comparados com os obtidos pela aplicação de um modelo de auto-regressão multivariada similar ao de Richardson (1981). O modelo reproduziu satisfatoriamente as médias, desvios, correlações entre variáveis e auto-correlações.

2.1.3 Validação dos modelos

Uma grande dificuldade relacionada com o desenvolvimento de modelos hidrológicos é a validação dos resultados obtidos. Validar um modelo analítico significa determinar se o modelo apresentado é uma representação precisa do sistema real. Neves, Chambel-Leitão e Leitão (2000) afirmam que a validação de um modelo pode ser realizada comparando os dados gerados com dados observados ou com os resultados de outros modelos que já tenham sido objeto de verificação e validação. Com isso, os resultados do modelo desenvolvido pelos autores foram comparados com os resultados do modelo HYDRUS, com o objetivo de validar o primeiro tirando proveito do elevado número de testes a que o segundo já havia sido submetido. Oliveira (2003), para a validação do modelo para geração de séries sintéticas de precipitação (ClimaBR) por ele desenvolvido, utilizou um procedimento semelhante, comparando as séries sintéticas geradas para 100 anos pelo modelo proposto com as séries geradas por um modelo consagrado na literatura, o CLIGEN. Diversos autores (LARSEN; PENSE, 1982; VIRGENS FILHO, 1997, 2001; OLIVEIRA, 2003) utilizaram procedimentos estatísticos para comparar os dados climáticos gerados com os observados, dentre eles: a) testes de qui-quadrado e Kolmogorov-Smirnov, para

verificar o ajuste dos dados climáticos estudados às distribuições de frequência acumulada; b) regressão linear entre as médias mensais observadas e geradas; c) teste t aplicado aos coeficientes de regressão, para avaliar o comportamento dos valores médios simulados diante dos valores médios históricos; d) teste F, para comparar as variâncias; e) coeficientes de correlação e determinação; e f) erro relativo percentual, para estimar a diferença entre os valores estimados e observados. O teste t e o teste F têm sido utilizados em trabalhos na área de hidrologia e de conservação de água e solo para comparação de médias e variâncias, respectivamente. Gomes (1970), no entanto, afirma que não fica provada com sua utilização a igualdade entre as médias e variâncias, mas, no máximo, que não se têm motivos para afirmar que sejam diferentes a um determinado nível de probabilidade.

2.2 Geoestatística

A técnica da geoestatística foi elaborada por Krige (1951) e desenvolvida posteriormente por Matheron (1963), o qual formulou a base da teoria das variáveis regionalizadas. Esse procedimento permite detectar se determinado parâmetro está, de alguma forma, relacionados à sua distribuição espacial. De acordo com Vieira (2000) um dos procedimentos mais antigos de estimar a dependência espacial ou temporal de amostras vizinhas é através da autocorrelação, a qual foi muito utilizada por vários autores no estudo de propriedades do solo (WEBSTER, 1973); (VIEIRA; NIELSEN; BIGGAR, 1981; LIBARDI; PREVEDELLO, 1986; REICHARDT; VIEIRA, 1986; SILVA; LIBARDI; VIEIRA, 1989).

Tal procedimento é representativo quando se tem amostragem realizada somente em uma direção, como é o caso dos transectos. No entanto, se as amostras forem coletadas em duas dimensões, há a necessidade de se utilizar o semivariograma que é uma ferramenta mais adequada para essa situação (VIEIRA, 2000).

A geoestatística é fundamentada no princípio da variância dos dados em função da distância. Quanto mais próximas as amostras, maior a probabilidade de serem parecidas em relação a uma amostra mais distante (VIEIRA, 2000). Para que haja dependência espacial, as observações tomadas a curtas distâncias devem ser mais semelhantes do que aquelas tomadas a distâncias maiores (JOURNEL; HUIJBREGTS, 1991). Essa hipótese depende da formação do semivariograma. O semivariograma é representado pela variância em função da distância. Ele

demonstra a correlação dos dados com sua localização, já que a variância tende a aumentar entre dados mais distantes.

Segundo Vieira (2000), esta ferramenta é mais adequada para medir a dependência espacial quando amostras forem coletadas em duas dimensões no campo e é necessário interpolar locais não amostrados com intuito de gerar mapas de isolinhas. O semivariograma pode ser definido como Clark (1979).

$$\sigma(h) = 1/2E[Z(x_i) - Z(x_i + h)]^2 \quad (1)$$

ou seja a metade da esperança matemática do quadrado da diferença entre os valores dos pontos em um campo, distanciados do vetor distancia h. A equação pode ser dada por:

$$\sigma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (2)$$

em que N(h) é o número de pares, separados por um vetor h se a variável for escalar, de valores medidos Z(x_i) e Z(x_i+h).

O gráfico de $\sigma(h)$ versus distância (h) representa o semivariograma, que permite obter a estimativa do valor de semivariância para as diferentes combinações de pares de pontos e assim analisar o grau de dependência espacial da variável estudada e definir os parâmetros necessários para a estimativa de suas características em locais não amostrados (SOUZA, 1999). A medida que aumenta h, $\sigma(h)$ também aumenta pois é de se esperar que amostras tiradas a uma pequena distância entre si apresentem $[Z(x_i) - Z(x_i + h)]^2$ menores que aquelas tiradas a distâncias maiores (SILVA, 1988; CAMARGO, 1997). O ajuste do modelo matemático aos dados no gráfico, ou seja, a uma função, define os parâmetros do semivariograma, que são: efeito pepita (Co), que é o valor de quando h=0; quando h aumenta freqüentemente, aumenta até uma distância a, chamada de alcance (a) da dependência espacial; e a partir da qual $\sigma(h)$ neste ponto é chamado de patamar (C+Co), cujo valor é aproximadamente igual à variância dos dados, se ela existe, e é obtido pela soma do efeito pepita e a variância estrutural (C). No comportamento típico de um semivariograma ajustado, o valor de semivariância aumenta à medida que aumenta sua distância de separação entre os pontos, até estabilizar-se, ou seja, atingir um patamar (VIEIRA, 2000).

O patamar é atingido quando a variância dos dados se torna constante com a distância entre as amostras. O valor de $\sigma(h)$ nesse ponto é aproximadamente igual à variância total dos dados, parâmetro importante, pois permite a determinação da distância limite entre dependência e

independência entre das amostras (SILVA, 1988). O efeito pepita reflete o erro analítico, indicando uma variabilidade não explicada (ao acaso) de um ponto para o outro, que pode ser devida tanto a erros de medidas ou microvariação não detectada em função da distância de amostragem utilizada, sendo impossível quantificar a contribuição individual dos erros de medições ou da variabilidade.

Dependendo do comportamento do semivariograma para grandes valores de h , o modelo a ser usado pode ser classificado em duas categorias: a) modelo sem patamar e b) modelo com patamar. Os modelos com patamar normalmente são ajustes que representam a estacionaridade de segunda ordem, onde a semivariância aumenta com o aumento da distância entre amostras, até atingir o patamar, onde se estabiliza (MACHADO, 1994).

Já os modelos sem patamar satisfazem apenas a hipótese intrínseca e os semivariogramas podem ser definidos, mas não se estabilizam em nenhum patamar. Um exemplo de semivariograma é apresentado na Figura 1.

Figura 1 - Exemplo de semivariograma

2.2.1 Solo

A formação dos solos não é homogênea ao longo do tempo, tampouco no espaço, e muitas vezes suas propriedades não variam ao acaso, mas apresentam dependência espacial ou temporal. Essa dependência pode invalidar o uso de análises estatísticas convencionais em experimentos de campo, especialmente naqueles que utilizam grandes parcelas. Desse modo, é importante o conhecimento do comportamento espacial ou temporal da variável em estudo para se escolher o

modelo matemático adequado (BERNER et al., 2007). A análise de dados para o estudo da variabilidade espacial de um solo depende essencialmente do método de amostragem (REICHARDT; VIEIRA, 1986; SILVA, 1988; BURROUGH, 1993). Berner et al. (2007) coletaram amostras de solo em uma área total de 4.422 m², num reticulado de sete linhas e sete colunas, com espaçamento constante de 9,5 m entre linhas e colunas. Dessa forma, formaram-se 49 células, em cujo centro foram localizados os pontos de amostragem. Foram utilizados semivariogramas para avaliar a estrutura da variância e caracterizar a dependência espacial das propriedades do solo em cada área.

Verificaram-se diferenças quanto à granulometria do material de origem dos dois solos, uma vez que os semivariogramas apontaram correlações distintas para cada área. Gomes et al. (2007) diagnosticaram o uso atual das terras e suas implicações na variabilidade espacial dos atributos físicos densidade do solo (Ds), matéria orgânica (MO), frações texturais (areia, silte e argila) e argila dispersa em água (ADA), na bacia hidrográfica do Ribeirão Marcela, Região Alto Rio Grande, MG, através de técnicas de geoestatística, com a finalidade de observar padrões de ocorrência desses atributos na paisagem. Coletaram-se amostras de solo na camada de 0 a 0,15 m em malha, com intervalos regulares de 240 x 240 m (macroescala) e de 60 x 60 m (microescala), totalizando 165 pontos. A Ds apresentou-se com valores na faixa de 1,05 a 1,15 g cm⁻³ acima, portando, do valor característico para Latossolos (0,95 g cm⁻³), enquanto os maiores valores foram obtidos nas glebas sob pastejo. Os valores de MO variaram de 1,5 a 4,5 dag kg⁻¹, detectando-se maiores concentrações nas glebas sob eucalipto, cerrado mais denso e várzeas. As frações texturais variaram seguindo a rede de drenagem e a ADA indicou valores baixos ao longo de toda a bacia. Os mapas de krigagem mostraram-se importante no estudo e compreensão da variabilidade espacial de atributos físicos do solo na bacia hidrográfica, indicando áreas críticas de manejo. Percebe-se que a variabilidade espacial de atributos químicos e físicos do solo existem em pequenas áreas, sendo fácil compreender a sua existência em áreas com o tamanho do Estado do Mato Grosso. No entanto, existem casos como o de Carvalho e Silveira (2002), que utilizando a geoestatística, estudaram a variabilidade espacial de componentes químicos no solo no cultivo de cereais, permitindo indicar a ausência de dependência espacial dos compostos nas práticas culturais.

2.2.2 Temperatura

Comparando o resultado obtido por diferentes métodos de interpolação disponibilizados por SIG, aplicados à estimativa da temperatura média do ar em Portugal Continental, no período de 1961-1990, Silva (2005) apresentou mapas descrevendo a espacialização das diferentes temperaturas que ocorrem naquele país.

Camargo, Felgueiras e Monteiro (2001) enfatizaram a importância à modelagem da anisotropia na distribuição espacial de variáveis ambientais com uso de procedimentos geoestatísticos, especificamente a Krigagem. (ROMANI et al., 2003) apresentaram a simulação dos dados coletados de estações meteorológicas por meio da internet e estimam a temperatura de outros locais através de média ponderada e do método de interpolação do inverso do quadrado da distância, utilizando informações de estações vizinhas. Em um curso que parte da estatística para a geoestatística exploratória e multivariada, Wackernagel (1998) abordou modelos, formulações e métodos de estatística espacial para resolução de problemas, apresentou exemplos de regiões mais amplas e globais em detrimento a uma especificação mais pormenorizada de microrregiões, apresentando os semivariogramas de forma didática.

2.2.3 Precipitação

Vendrusculo, Carvalho e Vieira (2003) analisaram a distribuição espacial da precipitação pluvial anual média de mil e vinte e sete estações climáticas abrangendo o Estado de São Paulo no período compreendido entre 1957 a 1997 utilizando o software geostatístico denominado GeoEst, desenvolvido em ambiente Delphi 5. A análise do semivariograma relativo à precipitação anual mostrou dependência espacial para um alcance de 48,5 km. A isotropia foi constatada para este caso. O modelo teórico esférico foi aquele que representou o melhor ajuste aos pontos do semivariograma experimental. A análise do mapa de variabilidade confirmou a influência da altitude nos altos índices de precipitação da costa litorânea do estado de São Paulo.

Guimarães, Oliveira e Tavares (2005) , em estudos sobre o comportamento espacial da precipitação no estado de Minas Gerais, respectivamente para o verão e para o total anual, verificaram a necessidade de considerar a distribuição espacial em estimativas desse atributo. Este trabalho visou verificar a ocorrência de dependência espacial e temporal da precipitação pluviométrica mensal para o estado de Minas Gerais utilizando semivariogramas e também mapear as precipitações mensais por meio da krigagem.

Em estudo sobre o comportamento da precipitação pluviométrica, Vieira, Lombardi Neto e Burrows (1991) realizaram o mapeamento das chuvas diária máxima provável para o estado de São Paulo e utilizaram a autocorrelação espacial, calculada pelo semivariograma, para verificar a dependência espacial e realizar estimativas para os locais onde não se têm valores medidos, utilizando a técnica da krigagem. Assad, Assad e Evangelhista (1994) apresentaram uma análise sobre chuvas extremas na região dos cerrados.

Estudando o comportamento espacial do percentil 75 da precipitação decendial do estado de São Paulo, Gomes (2001) elaborou mapas de isoietas, utilizando como ferramenta principal a Geoestatística. Cardim (2001) realizou o mapeamento multivariado das principais variáveis climáticas de interesse agrícola do estado de São Paulo e a Geoestatística permitiu analisar a variabilidade espacial dos índices climáticos obtidos (índice térmico, índice pluviométrico e índice pluviotérmico). Para o Estado do Paraná, Zamboti (2001) realizou o mapeamento de chuvas médias mensais nos meses de verão, utilizando como ferramenta de análise da dependência espacial e interpolação de dados, respectivamente, o semivariograma e a krigagem. No Triângulo Mineiro, especificamente para a cidade de Uberaba, Veronese e Guimarães (2002) e Silva, Guimarães e Tavares (2003) realizaram estudos do comportamento temporal da temperatura média mensal e da precipitação mensal, utilizando metodologias da geoestatística.

Macedo et al. (2001) utilizaram métodos geoestatísticos como alternativa ao interpolador média ponderada com vista a comparar diferentes métodos e identificar o mais adequado para a espacialização de datas de plantio de cereais. Ao incorporarem a altitude como variável auxiliar na determinação do mapa de variabilidade espacial de precipitação pluvial para o Estado de São Paulo, (CARVALHO; ASSAD, 2003) utilizaram um interpolador geoestatístico multivariado, a co-krigagem, obtendo resultados considerados bons para o período analisado.

2.3 Correlação de parâmetros climáticos com as coordenadas e altitude

A utilização de Sistemas de Informações Geográficas tem permitido a caracterização espaço-temporal de variáveis ambientais, dentre as quais se incluem as agroclimáticas. O desenvolvimento de sistemas computacionais para aplicações gráficas vem, cada vez mais, influenciando as áreas de cartografia, mapeamento, análise de recursos naturais e planejamento regional (REIS et al., 2007).

2.3.1 Temperatura

Cargnelutti Filho, Maluf e Matzenauer (2006) descrevem que a temperatura mínima média decendial do ar pode ser estimada por meio de coordenadas geográficas e que a altitude e a latitude exercem influência sobre essa temperatura.

Cargnelutti Filho, Maluf e Matzenauer (2006) verificaram com dados de temperatura mínima média decendial do ar (T_m) de 41 municípios do Estado do Rio Grande do Sul, de 1945 a 1974, se a T_m pode ser estimada em função da altitude, latitude e longitude. Para cada um dos 36 decêndios do ano, realizaram-se análise de correlação, análise de trilha das variáveis causais altitude, latitude e longitude sobre o efeito T_m , e estimaram-se os parâmetros do modelo das equações de regressão linear múltipla, pelo método passo a passo, com teste para saída de variáveis, considerando T_m como variável dependente e altitude, latitude e longitude como variáveis independentes. Na validação dos modelos de estimativa da T_m , usou-se o coeficiente de correlação linear de Pearson, entre a T_m estimada e a T_m observada em dez municípios do Estado, com dados da série de observações meteorológicas de 1975 a 2004. A temperatura mínima média decendial do ar pode ser estimada pelas coordenadas geográficas em qualquer local e decêndio, no Estado do Rio Grande do Sul. A altitude e latitude explicam melhor a variação da T_m .

Estefanel et al. (1973) realizaram, no Estado do Rio Grande do Sul, estimativa das médias das temperaturas mínimas mensais e anuais em função da altitude e latitude. Da mesma maneira que Buriol et al. (1973), concluíram que as equações podem ser usadas para estimar as temperaturas médias das máximas, em todo o Estado, com exceção da faixa litorânea. O efeito de baixa correlação na faixa litorânea é atribuído, provavelmente, à influência das grandes lagoas e do oceano. A estimativa da temperatura do ar mínima, média e máxima mensal e anual, a partir das coordenadas geográficas, tem sido estudada nos estados de Minas Gerais (COELHO; SEDIYAMA; VIEIRA, 1973; SEDIYAMA; MELO JÚNIOR, 1998), Espírito Santo (FEITOZA et al., 1980a, 1980b) e Piauí (LIMA; RIBEIRO, 1998), e em regiões do Brasil (OLIVEIRA et al., 2002; MEDEIROS et al., 2005).

Segundo Estefanel et al. (1973), as temperaturas médias do ar, no Estado do Rio Grande do Sul, podem ser estimadas pela correlação entre a altitude e latitude, exceto para a faixa litorânea. Em virtude da pequena variação da latitude na área de estudo, inferior a 1, e também em função da obtenção de um baixo coeficiente de determinação não significativo entre a temperatura e a latitude, esta variável não foi utilizada na estimação das temperaturas.

Segundo Medeiros et al. (2005), o ajuste das equações de regressão para estimativa das normais de temperaturas mínimas, médias e máximas é uma alternativa viável para ampliar a base de dados climáticos, através de mapas temáticos de temperatura, fornecendo subsídios para um melhor planejamento agropecuário.

Estatisticamente, usa-se a análise de regressão, que é o método de análise apropriado quando o problema envolve uma única variável dependente (critério), considerada relacionada a duas ou mais variáveis independentes, cujos valores são conhecidos, para prever os valores da variável dependente selecionada (DILLON; GOLDSTEIN, 1984). Em regressão múltipla, a variável estatística é determinada de modo a melhor correlacionar com a variável a ser prevista. Fornece um meio de avaliar objetivamente o grau e caráter da relação entre variáveis dependentes e independentes, pela formação da variável estatística de variáveis independentes. Estas, além de sua previsão coletiva da variável dependente, também podem ser consideradas por sua contribuição individual à variável estatística e suas previsões. A interpretação da variável estatística pode se apoiar em qualquer uma de três perspectivas: a importância das variáveis independentes, os tipos de relações encontradas ou as inter-relações entre as variáveis independentes. A correlação entre as variáveis independentes pode tornar algumas variáveis redundantes no esforço preditivo.

Desse modo, elas não são necessárias para produzir a previsão ótima. Isso não reflete suas relações individuais com a variável independente, mas indica que, em um contexto multivariado, elas não são necessárias se um outro conjunto de variáveis independentes que explique essa variância for empregado.

2.3.2 Precipitação

Mello, Pedro Júnior e Lombardi Neto (1994) julgam indispensável a caracterização espacial e temporal das condições hídricas para melhor entender o clima da região e ressaltam também a importância da caracterização da distribuição de chuva para as ciências ambientais e para a engenharia.

Para Mellaart (1999), a distribuição da chuva ou precipitação pluvial depende da topografia local e do tipo de chuva. O autor observou importantes diferenças na variabilidade espacial das chuvas para distâncias relativamente pequenas (1 km), mas ressaltou que o grau de variabilidade muda de ano para ano e de região para região, o que torna necessário pesquisas

regionais e constantes para obtenção de elementos mais significativos para a variabilidade espacial.

Bega et al. (2005) estudou a variabilidade espacial das chuvas diárias em uma escala reduzida em Pindorama, São Paulo, Brasil, utilizando dados que cobriram um período de 32 anos. Os dados históricos de cinco pluviômetros, cujas distâncias entre si variam de 257 a 3.900 metros, foram submetidos à análise de correlação para determinar a variabilidade espacial. A medida que a distância entre os pluviômetros aumentou, o coeficiente de correlação dos dados de chuvas por eles medidos diminuiu, revelando que a precipitação pluvial depende das posições onde se localizam os pluviômetros. As médias diárias mostraram que pluviômetros próximos, porém sob maiores variações de altitude, possuem diferenças superiores a pluviômetros mais distantes, mas sob altitudes similares. Quanto ao comprimento da série, evidenciou-se que, para o estudo, as séries deveriam possuir no mínimo sete anos.

Vendrusculo, Carvalho e Vieira (2003) analisaram a distribuição espacial da precipitação pluvial anual média de estações climáticas abrangendo o Estado de São Paulo no período compreendido entre 1957 a 1997 utilizando o software geoestatístico denominado GeoEst, desenvolvido em ambiente Delphi 5. A análise do semivariograma relativo à precipitação anual mostrou dependência espacial para um alcance de 48,5 km. A isotropia foi constatada para este caso. O modelo teórico esférico foi aquele que representou o melhor ajuste aos pontos do semivariograma experimental. A análise do mapa de variabilidade confirmou a influência da altitude nos altos índices de precipitação da costa litorânea do estado de São Paulo.

2.4 Balanço hídrico

O balanço hídrico surgiu da necessidade de se contabilizar a chuva e a evapotranspiração que ocorre em um ecossistema, com o objetivo de se conhecer a disponibilidade de água para as plantas, ao longo do ano. Visando equacionar esta relação, surgiram diferentes métodos de se calcular o balanço hídrico. Dentre estes, o que apresentou maior difusão foi o de Thornthwaite e Mather (1955), por considerar que a disponibilidade de água no solo diminui à medida que o armazenamento é reduzido, estabelecendo assim, o solo como um ingrediente ativo no seu cálculo. O balanço hídrico climatológico desenvolvido por Thornthwaite e Mather (1955) é uma das várias maneiras de se monitorar a variação do armazenamento de água no solo, tanto na escala diária como em escalas maiores como a mensal, utilizando-se valores médios de vários anos

(normal climatológica). Através da entrada desses dados, fornece estimativas da evapotranspiração real (ET_r), da deficiência hídrica (DEF), do excedente hídrico (EXC) e do armazenamento de água do solo (ARM). Segundo Rolim, Sentelhas e Barbieri (1998) o balanço hídrico é uma ferramenta empregada em distintas áreas do conhecimento. Por exemplo: na meteorologia agrícola, delimita áreas de mesmo potencial hídrico, na irrigação, determina as deficiências hídricas de uma região, na hidrologia, estuda as bacias hidrográficas, dimensionando reservatórios. Os resultados de um balanço hídrico podem ser utilizados para fins de zoneamento agroclimático, demanda potencial de água das culturas irrigadas e no conhecimento do regime hídrico.

O balanço hídrico climatológico é uma das várias maneiras de se monitorar a variação do armazenamento de água no solo. A partir do suprimento de água ao solo, via precipitação ou irrigação, da demanda atmosférica e da capacidade de água disponível, o balanço hídrico fornece estimativas da evapotranspiração real, da deficiência, do excedente hídrico e do armazenamento de água no solo. O balanço hídrico assim calculado torna-se um indicador climatológico da disponibilidade hídrica em uma região (PEREIRA, 1997), o que é fundamental no planejamento das atividades agrícolas. Para Aguilar, Kruker e Calheiros (1986) os resultados de um balanço hídrico podem ser úteis no processo de zoneamento agroclimático de uma região, cálculo da demanda potencial de água das culturas irrigadas, definição de prioridades no planejamento de pesquisas ou, ainda, no conhecimento do regime hídrico.

Para Sentelhas, Pereira e Angelocci (1998), o balanço hídrico climatológico tem sua principal função estabelecida na caracterização regional quanto à disponibilidade hídrica. Conhecer o balanço hídrico para uma determinada região é de extrema relevância, pois este fornece a contabilização da água do solo, resultante da aplicação do Princípio de Conservação de Massa em um volume de solo vegetado (PEREIRA; ANGELOCCI; SENTELHAS, 2002).

2.4.1 Pedotransferência para estimativa da capacidade de armazenamento de água no solo

Bouma (1989) introduziu o termo *pedotransfer functions* (PTF) para designar as relações de dependência de parâmetros de transferência de massa por meio de dados de solos disponíveis em levantamentos normalmente realizados. Inúmeras PTFs têm sido propostas visando estimar a água disponível a partir de propriedades físicas do solo (RAWLS; GISH; BRAKENSIEK, 1991) sendo a textura, um dos elementos mais utilizados (OSTER-VELD; CHANG, 1980; SAXTON;

RAWLS; ROMBERGER, 1986; ARRUDA, ZULLO JR. e OLIVEIRA, 1987; BERG; KLAMT; REEUWIJK, 1997; TOMASELLA, 2000). Em geral, dois tipos de modelos são empregados, ambos utilizando análises de regressão: a estimativa de valores de retenção de água e a estimativa de parâmetros para cálculo da retenção de água (RAWLS; GISH; BRAKENSIEK, 1991). Em potenciais mais elevados (inferior a -10 kPa), a quantidade de água retida depende da porosidade, da estrutura e da densidade do solo. À medida que a umidade diminui, a adsorção de água tende a prevalecer e a quantidade de água retida passa a ser cada vez mais dependente de propriedades relacionadas com a superfície específica do solo, tais como: textura, conteúdo de matéria orgânica e mineralogia da fração argila (WILLIAMS; PREBBLE; WILLIAMS, 1983).

Vários fatores afetam a retenção da água em um solo, mas o principal deles é a textura, pois ela, diretamente, determina a área de contato entre as partículas sólidas e a água determinando assim as proporções de poros de diferentes tamanhos (REICHARDT, 1990).

Outro fato que mencionam é que a matéria orgânica na fase coloidal também possui boas propriedades de retenção de água. A matéria orgânica afeta uma das principais características físicas do solo, a agregação do solo, afetando assim, indiretamente, outras características como a densidade, porosidade, aeração e capacidade de retenção e infiltração de água (SANTOS; CAMARGO, 1999). As funções de pedotransferência podem ajudar a desenvolver valores de potencial matricial e pode prever a expressão da curva de retenção da água (HILLEL, 1998).

3 MATERIAL E MÉTODOS

3.1 Obtenção das séries históricas das variáveis climáticas

Os dados referentes às variáveis climáticas foram obtidos do Instituto Nacional de Meteorologia Agrícola (INMET) e da Agência Nacional de águas (ANA). As Figuras 2 e 3 mostram as localidades de cada estação meteorológica fornecida para a modelagem feita nesta dissertação.

Figura 2 - Mapa das estações meteorológicas fornecidas pelo INMET

Figura 3 - Mapa das estações hidrometeorológicas fornecidas pela ANA

De cada uma das estações meteorológicas e hidrometeorológicas foi extraído o valor médio, máximo e mínimo de temperatura e precipitação, o desvio padrão das duas variáveis, além da correlação com o dia anterior e a probabilidade de chover ou não.

Todos esses valores foram obtidos para cada dia do ano, obtendo-se ao final 366 valores de cada uma dessas variáveis em todas estações meteorológicas e hidrometeorológicas.

3.2 Regressão linear multivariada

Estimaram-se os coeficientes lineares da regressão linear múltipla entre as variáveis temperatura média (T_m) versus altitude, latitude e longitude, desvio padrão da temperatura (σ_T) versus altitude, latitude e longitude, precipitação média (P_m) versus altitude, latitude e longitude, precipitação mínima ($P_{\min}$) versus altitude, latitude e longitude, precipitação máxima ($P_{\max}$) versus altitude, latitude e longitude, desvio padrão da chuva (σ_P) versus altitude, latitude e longitude, probabilidade de chover (η_P) versus altitude, latitude e longitude, correlação da temperatura (ρ_T) e

precipitação (ρ_P) com o dia anterior versus altitude, latitude e longitude para cada dia do ano e verificou-se a significância a 5% de probabilidade. Em cada matriz foi usado o modelo de regressão linear múltipla com k variáveis independentes conforme a equação 3:

$$Y_j = \beta_0 + \sum_{i=1}^k \beta_i X_{ij} + \varepsilon_j. \quad (3)$$

em que Y_j é o valor observado da T_m , P_m , $P_{\min}$, $P_{\max}$, σ_T , σ_P , ρ_T , ρ_P , η_P ; β_0 é o coeficiente linear; β_i é o coeficiente de regressão das variáveis independentes, X_i ; X_{ij} são as variáveis independentes X_i na observação j ; e ε_j é o erro associado a variável Y na observação j . Nesse modelo, a variável Y é função linear das variáveis independentes, os valores das variáveis independentes são fixos e os erros tem média zero, são homocedásticos, independentes e de distribuição normal (DRAPER; SMITH, 1996; NETER, 1997; HOFFMANN; VIEIRA, 1998; SOUZA, 1998). Os parâmetros do modelo das equações de regressão linear múltipla foram estimados considerando T_m , P_m , $P_{\min}$, $P_{\max}$, σ_T , σ_P , ρ_T , ρ_P , η_P , respectivamente, como variável dependente e as demais altitude (em metros), latitude (em graus - valores negativos) e longitude (em graus - valores negativos)], foram consideradas como independentes.

3.3 Criação de séries sintéticas

O modelo para a criação de séries sintéticas seguiu o raciocínio proposto por Richardson, (1981), assumindo o processo multivariado contínuo usado por Matalas, (1967) para gerar séries de resíduos de temperatura média, e precipitação média.

3.3.1 Temperatura

O resíduo estimado referente à temperatura média do ar de cada dia em cada ano pode ser computado a partir da seguinte equação:

$$Y_{p,i} = \frac{x_{p,i} - \bar{x}_i}{\sigma_i} \quad (4)$$

O coeficiente de autocorrelação entre dois dias consecutivos pode ser expressado como:

$$\rho = \frac{(n-1) \sum_{i=1}^{n-1} x_{p,i} x_{p,i+1} - \sum_{i=1}^{n-1} x_{p,i} \sum_{i=1}^{n-1} x_{p,i+1}}{\sqrt{(n-1) \sum_{i=1}^{n-1} (x_{p,i})^2 - (\sum_{i=1}^{n-1} x_{p,i})^2} \sqrt{(n-1) \sum_{i=1}^{n-1} (x_{p,i+1})^2 - (\sum_{i=1}^{n-1} x_{p,i+1})^2}} \quad (5)$$

O modelo básico usado para a geração de séries sintéticas como definido por (MATALAS, 1967) é o processo mostrado a seguir:

$$\hat{Y}_{p,i+1} = \rho_i Y_{p,i} + \varepsilon_{p,i+1} \quad (6)$$

$$\hat{Y}_{p,i+1} = \varepsilon_{p,i+1} \quad (7)$$

em que $\hat{Y}_{p,i+1}$ é a estimativa do residual Y_{pi+1} , exceto para o primeiro dia ($\hat{Y}_{p,i+1} = Y_{pi+1}$), sendo ε_{pi+1} o componente randômico independente de x_{pi} que possui média zero e desvio padrão igual a 1.

Finalmente, a simulação da temperatura média do ar diária ($\hat{T}_{pi}$) pode ser computada através da seguinte equação:

$$\hat{T}_{p,i} = \hat{Y}_{p,i} \sigma_i + \bar{x}_i \quad (8)$$

3.3.2 Precipitação

A precipitação deve considerar a probabilidade de chover ou não para que seja gerada a série sintética. Dessa forma a probabilidade de não chover foi considerada como:

$$\eta = \frac{dn}{dt} \quad (9)$$

em que η é probabilidade de não chover, dn é o número de anos na série histórica sem chuva em determinado dia, dt é o número de anos existentes na série histórica.

Obtendo-se a probabilidade de não chover (η) cria-se um número randômico (r_1) de 0 a 1. Se $r_1 < 0$ a precipitação média naquele dia é igual a zero, se $r_1 > 0$, a precipitação média daquele dia segue o procedimento similar à estimativa da temperatura da seguinte forma: primeiramente é necessário gerar o resíduo estimado da precipitação média. No entanto, o resíduo estimado referente à precipitação média de cada dia em cada ano não pode ser considerado com distribuição normal. Pela dificuldade em se determinar a distribuição da chuva atribuiu-se precipitação máxima subtraindo a média como o desvio padrão, se a chuva for maior que a média e a precipitação média subtraída da mínima, caso a chuva seja menor que a média. Dessa forma, usou-se um número randômico (r) entre -1 e 1 sendo o desvio padrão considerado como:

$$\sigma_i = P_{\max} - P_m \rightarrow (r > 1) \quad (10)$$

em que $P_{\max}$ é a máxima precipitação observada e P_m a precipitação média do dia

$$\sigma_i = P_{\min} - P_m \rightarrow (r < 1) \quad (11)$$

em que $P_{\min}$ é a mínima precipitação observada e P_m a precipitação média do dia

Dessa forma o resíduo pode ser calculado como:

$$Y_{p,i} = \frac{x_{p,i} - \bar{x}_i}{\sigma_i} \quad (12)$$

O coeficiente de autocorrelação entre dois dias consecutivos pode ser expressado como:

$$\rho = \frac{(n-1) \sum_{i=1}^{n-1} x_{p,i} x_{p,i+1} - \sum_{i=1}^{n-1} x_{p,i} \sum_{i=1}^{n-1} x_{p,i+1}}{\sqrt{(n-1) \sum_{i=1}^{n-1} (x_{p,i})^2 - (\sum_{i=1}^{n-1} x_{p,i})^2} \sqrt{(n-1) \sum_{i=1}^{n-1} (x_{p,i+1})^2 - (\sum_{i=1}^{n-1} x_{p,i+1})^2}} \quad (13)$$

O modelo básico usado para a geração de séries sintéticas como definido por Matalas (1967) é o processo mostrado a seguir:

$$\hat{Y}_{p,i+1} = \rho_i Y_{p,i} + \varepsilon_{p,i+1} \quad (14)$$

$$\hat{Y}_{p,i+1} = \varepsilon_{p,i+1} \quad (15)$$

em que $\hat{Y}_{p,i+1}$ é a estimativa do residual Y_{pi+1} , exceto para o primeiro dia ($\hat{Y}_{p,i+1} = Y_{pi+1}$), sendo ε_{pi+1} o componente randômico independente de x_{pi} que possui média zero e desvio padrão igual a 1.

Finalmente, a simulação da temperatura média do ar diária ($\hat{P}_{pi}$) pode ser computada através da seguinte equação:

$$\hat{P}_{p,i} = \hat{Y}_{p,i} \sigma_i + \bar{x}_i \quad (16)$$

3.4 Validação do modelo

Foram geradas séries de temperatura média e precipitação média com 100 anos de duração para as 507 estações climatológicas estimadas (Figura 4). A comparação dos resultados obtidos com a aplicação do modelo desenvolvido e os valores observados foi feita utilizando as médias de precipitação diária e mensal, além da temperatura média diária e mensal. Foram utilizadas 17 estações meteorológicas distribuídas pelo estado do Mato Grosso para a comparação entre os dados observados e estimados, conforme a Figura 5.

Figura 4 - Mapa das estações meteorológicas estimadas

Figura 5 - Mapa das estações meteorológicas usadas para a validação do modelo

Os testes utilizados nesta comparação foram: a) erros relativos percentuais; b) coeficiente de correlação de Pearson c) índices de concordância (d) e de confiança (c)

O cálculo dos erros relativos percentuais (ERP) foi feito com o uso da equação seguinte:

$$ERP = \frac{E - O}{O} 100 \quad (17)$$

em que ERP é o erro relativo percentual, %; E é o valor estimado pelo modelo; e O é o valor observado. O ajuste de equações de regressão linear simples foi feito a fim de verificar a dispersão das médias mensais simuladas em relação às médias mensais observadas, sendo que a verificação foi feita por meio do coeficiente de correlação (r) das regressões. Em virtude do coeficiente de determinação fornecer apenas o grau de precisão do modelo, foi também calculado, com base na equação , o índice de concordância proposto por Willmott (1981), afim de se verificar o grau de exatidão com que a variável observada é estimada. Esse índice varia entre zero e um, sendo que, quanto mais próximo de um, melhor a exatidão do modelo em estimar a variável dependente.

$$d = 1 - \frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (18)$$

em que d é o índice de concordância; E_i é o i-ésimo valor estimado; O_i é o i-ésimo valor observado; e é a média dos valores observados. A fim de se analisar conjuntamente a precisão e a exatidão dos resultados obtidos, foi determinado também o índice de confiança (c), proposto por Camargo e Sentelhas (1997) e calculado pelo produto entre o coeficiente de correlação (r) e o índice de concordância (d). Neste caso foi adotado como critério de avaliação do desempenho do modelo os valores apresentados na Tabela 1.

Tabela 1 - Análise do desempenho do modelo com base no índice de confiança

Índice de confiança	Desempenho
>0,85	Ótimo
0,76-0,85	Muito Bom
0,66-0,75	Bom
0,61-0,65	Mediano
0,51-0,60	Ruim
0,41-0,5	Muito Ruim
<0,41	Péssimo

3.5 Pedotransferência

Os modelos de pedotransferência podem ser usados para estimar a curva de retenção do solo. As funções de pedotransferência usam valores de argila, silte, areia e matéria orgânica para estimar parâmetros de condutividade hidráulica do solo. Todos os parâmetros de solo usados nesta dissertação foram obtidos do levantamento de solo RADAM e interpolados pelo método da geoestatística, para a obtenção de dados em todas as coordenadas do Mato Grosso. Assim, pode-se obter pontualmente o valor específico da CAD em todas as estações meteorológicas sintéticas, a partir das equações geradas pelo trabalho de Tomasella (2000). Os parâmetros da equação a seguir podem ser estimados por funções de pedotransferência:

$$\theta = \theta_r + \frac{\theta_s - \theta_r}{\left[1 + (\alpha\tau)^n\right]^m} \quad (19)$$

em que θ é o conteúdo volumétrico do solo ($\text{cm}^3.\text{cm}^{-3}$), θ_s e θ_r são o conteúdo volumétrico saturado e residual, respectivamente, τ é o valor absoluto do potencial mátrico do solo (kPa); α (kPa^{-1}), n e m são parâmetros derivados de observações fixas em determinado potencial mátrico. Genuchten (1980) assumiu $m=1-1/n$, o que permite derivar uma expressão analítica para a condutividade hidráulica.

Obtendo-se θ_r e θ , pode-se saber o volume de água disponível em determinado volume de solo. Dessa forma, consegue-se determinar a lâmina de água em milímetros disponível para a planta.

Tomasella (2000) usou a técnica de regressão linear múltipla para estabelecer a relação entre parâmetros do solo com a disponibilidade hídrica. Desse trabalho foram extraídas as seguintes equações:

$$\theta_r = 15,75 + 0,1358.C + 0,0052.C.S - 0,0028AG^2 - 0,0021AF^2 - 0,0045.S^2 \quad (20)$$

$$\theta_s = 36,97 + 0,3762.AF + 0,32576.MO - 0,0026.AG.C + 0,0034.AF.C - 0,0032.S.C + 0,0028.C^2 \quad (21)$$

$$n = 170,93 - 0,0179.AG.S - 0,0310.AF.C + 0,0094.AF^2 - 0,0081.S^2 \quad (22)$$

$$\ln\alpha = -237,0105 + 362,42.AG + 0,0043.AG.S + 0,0014.AG.C + 0,0898.AF.C + 0,0178.C^2 \quad (23)$$

em que AG é areia grossa, AF areia fina, S silte, C argila, MO matéria orgânica. θ_r ($\text{cm}^3.\text{cm}^{-3}$) é o conteúdo de água residual, ou seja, em potencial mátrico não disponível para a planta, θ_s ($\text{cm}^3.\text{cm}^{-3}$) o conteúdo de água na saturação do solo, n e $\ln(\alpha)$ são parâmetros referentes ao potencial mátrico da capacidade de campo considerada em (-10kPa). Dessa forma a capacidade de campo pode ser estimada a partir da seguinte equação:

$$CAD = 10(\theta_{cc} - \theta_{pmp}) Z \quad (24)$$

em que CAD é a capacidade de armazenamento do solo em mm, θ_{cc} e θ_{pmp} os conteúdos volumétricos na capacidade de campo e no ponto de murcha permanente ($\text{cm}^3.\text{cm}^{-3}$), respectivamente, e Z a profundidade efetiva (cm) da raiz.

3.6 Balanço hídrico

Utilizou-se o método de Thornthwaite e Mather (1955) para o cálculo do BH Normal. Este método considera que a variação do armazenamento (ARM) de água do solo é uma função exponencial que envolve capacidade de água disponível (CAD) (Função da profundidade de exploração efetiva das raízes e características físicas do solo) e perda de água acumulada (Negativo Acumulado). Para a estimativa da ETp os programas utilizam o procedimento proposto por Thornthwaite (1948), o qual tem a vantagem de necessitar apenas dos dados de temperatura média do ar dos períodos e da latitude local e fornece resultados confiáveis entre as latitudes de 40°N e 40°S (DOURADO-NETO; JONG VAN LIER, 1991). A inicialização do BH Normal segue o critério de Mendonça (1958).

4 RESULTADOS E DISCUSSÃO

O modelo proposto foi elaborado com o intuito de correlacionar parâmetros climáticos das estações meteorológicas de acordo com sua localidade e altitude. Através de regressões lineares múltiplas foi possível gerar valores necessários para criar séries sintéticas em qualquer localidade do Mato Grosso. No entanto, havia pouca informação meteorológica, que é perfeitamente compreensível em um estado de fronteira agrícola recente. Serão discutidos os resultados dos métodos aplicados nesta dissertação seguindo as etapas da metodologia aplicada.

4.1 Regressões lineares múltiplas para os dados diários de precipitação e temperatura

As regressões lineares múltiplas foram utilizadas para transpor os parâmetros usados pelos geradores sintéticos. Sendo assim, todos os parâmetros usados para criar séries temporais de temperatura e precipitação foram interpolados para que existissem em qualquer coordenada geográfica do Mato Grosso. Cada variável foi correlacionado com a coordenada geográfica e altitude, de forma a se criar equações específicas do dia do ano. Dessa correlação deriva-se uma equação diária em que as incógnitas são: latitude e longitude em graus e altitude em metros conforme apresentado na equação 3. As regressões de cada parâmetro são apresentadas posteriormente e analisadas individualmente.

$$Y_j = \text{INTERSEÇÃO} + X_{LAT} \cdot \text{Lat} + X_{LONG} \cdot \text{Long} + X_{ALT} \cdot \text{Alt} \quad (25)$$

em que Y_j é o parâmetro a ser estimado, Lat é a latitude (graus), Long é a longitude (graus) e 'Alt' é a altitude (m). INTERSEÇÃO, X_{LAT} , X_{LONG} e X_{ALT} são os parâmetros empíricos fornecidos pela análise de regressão.

Foram criados os parâmetros INTERSEÇÃO, X_{LAT} , X_{LONG} e X_{ALT} , respectivamente, referentes aos parâmetros β_0 e β_i da equação 3, transformada na equação 25 após a escolha dos parâmetros X_i e β_i . Para cada regressão foi feito um teste a 5% de probabilidade, determinando valores de significação.

As variáveis usadas para a criação de séries sintéticas de temperatura média, determinadas pela regressão são: temperatura média diária (T_m) e seu respectivo desvio padrão (σ_T), além da correlação entre o conjunto de dados de um determinado dia com o conjunto do dia anterior (ρ_T).

As variáveis usadas para a criação de séries sintéticas de precipitação média, conforme proposto nesta dissertação, determinadas pela regressão são: Precipitação média (P_m), máxima (P_{max}) e mínima (P_{min}), Probabilidade de não chover (η_p) e a correlação (ρ_p) entre dois dias

consecutivos. Nos poucos casos em que houve discordância entre os valores de P_m , P_{max} , P_{min} , usou-se o módulo da diferença como desvio padrão σ_P . Nesses casos a eficiência do modelo de regressão foi muito baixa, obtendo valores não significativos a 5% de probabilidade.

Todas as coordenadas do Mato Grosso passaram a ter os parâmetros apresentados nos parágrafos anteriores para todos os dias do ano. Tendo sido obtido valores de significação a 5% de probabilidade confiáveis para a maioria dos dias do ano. Dessa forma, pode-se usar o processo multivariado contínuo de Matalas, (1967) para gerar séries de resíduos de temperatura média, e precipitação média em qualquer localidade de Mato Grosso.

O resultado desse processo gerou séries sintéticas de temperatura e precipitação de 100 anos para 507 coordenadas geográficas. A validação desse modelo foi feita em 17 municípios confrontando a sequência diária da série histórica observada nas estações meteorológicas com a série sintética da coordenada mais próxima.

As tabelas 2, 3 e 4 do próximo capítulo fornecem os resultados classificados do confronto entre a série diária de temperatura, precipitação e probabilidade de não chover. As tabelas 5 e 6 fornecem os resultados classificados do confronto entre a série mensal de temperatura e precipitação. A classificação apresentada é referente ao índice de confiança (c), produto entre a concordância (d) e o coeficiente linear (r^2) do confronto entre a série sintética e observada. A classificação dos resultados mostra claramente a eficiência da modelagem para determinada localidade.

Percebe-se baixa correlação para a precipitação, o que pode ser explicado pelo desconhecimento da distribuição dos valores na utilização do processo contínuo multivariado. Sabe-se que não tem distribuição normal, fato que dificultou a aplicação do modelo. O método usado procurou contemplar valores máximos e mínimos, gerando valores condizentes com a realidade. Dessa forma, conseguiu-se valores mensais de precipitação com alta correlação com os valores observados, apesar dos dados diários apresentarem pouca conformidade e correlação.

A probabilidade de chover teve uma séria restrição devido às séries históricas baixas, tornando os valores restritos. Para minimizar essa restrição usou-se o número de anos na série histórica no processo de regressão, já que dessa forma conseguiu-se valores melhores de correlação com a série observada.

A temperatura foi o parâmetro que apresentou a melhor correlação, fato esperado devido à distribuição normal das variações diárias.

4.2 Geradores de série sintética: validação

4.2.1 Validação de dados diários

Tabela 2 - Índices de validação e classificação (c) do modelo de geração de séries de temperatura média diária

Estação	Lat	Long	Alt	Erp	r^2	D	c	C
Alta Floresta	-9,86	-56,1	267	0,11353	0,679564	0,908071	0,617092	m
Aragarças	-15,9	-52,23	308	2,350942	0,934289	0,754471	0,704894	b
Cáceres	-16,05	-57,68	123	0,827145	0,876292	0,584968	0,512603	r
Campos Novos dos Parecis	-13,78	-57,83	507	0,010878	0,493046	0,698922	0,344601	p
Canaranã	-13,5	-52,5	332	2,17876	0,696165	0,882245	0,614188	m
Cuiabá	-15,55	-56,12	186	1,947501	0,911376	0,673329	0,613656	m
Cuiabá (a)	-15,62	-56,1	150	3,674364	0,692165	0,874997	0,605642	r
Diamantino	-14,4	-56,45	268	1,449982	0,897455	0,644794	0,578673	r
Gleba Celeste	-12,2	-56,5	321	1,455003	0,763513	0,788499	0,602029	r
Matupá	-10,25	-54,92	264	0,798492	0,650965	0,8237	0,5362	r
Nova Xavantina	-14,7	-52,35	309	0,62441	0,905992	0,641279	0,580994	r
Poxoréo	-15,83	-54,38	334	2,163821	0,793742	0,773418	0,613895	m
Rondonópolis	-16,45	-54,57	269	0,454226	0,867181	0,572303	0,49629	mr
São José do Rio Claro (a)	-13,43	-56,72	337	0,074773	0,794766	0,6334	0,503405	mr
São Vicente	-15,82	-55,42	816	10,03681	0,623168	0,952433	0,593525	r
Sorriso	-12,55	-55,72	366	2,369565	0,287613	0,946207	0,272141	p
Tangará da Serra	-14,65	-57,42	456	4,436415	0,370406	0,93471	0,346222	p

(C) classificação: (b) bom, (m) mediano, (r) ruim, (mr) muito ruim e (p) péssimo.

Tabela 3 - Índices de validação e classificação (c) do modelo de geração de séries de precipitação média diária

Estação	lat	long	alt	erp	r ²	D	c	C
Alta Floresta	-9,86	-56,1	267	4,712214	0,247841	0,759273	0,188179	p
Aragarças	-15,9	-52,23	308	10,50897	0,707445	0,398753	0,282096	p
Cáceres	-16,05	-57,68	123	7,007949	0,469278	0,584077	0,274095	p
Campos Novos dos Parecis	-13,78	-57,83	507	31,51243	0,129531	0,80137	0,103803	p
Canaranã	-13,5	-52,5	332	12,20393	0,528746	0,631077	0,33368	p
Cuiabá	-15,55	-56,12	186	10,43116	0,423981	0,602589	0,255486	p
Cuiabá (a)	-15,62	-56,1	150	8,627892	0,427949	0,599422	0,256522	p
Diamantino	-14,4	-56,45	268	28,8438	0,631845	0,569115	0,359592	p
Gleba Celeste	-12,2	-56,5	321	15,49824	0,650815	0,540923	0,352041	p
Matupá	-10,25	-54,92	264	4,28882	0,400462	0,681861	0,273059	p
Nova Xavantina	-14,7	-52,35	309	8,069396	0,503921	0,628056	0,316491	p
Poxoréo	-15,83	-54,38	334	15,51899	0,524603	0,57926	0,303881	p
Rondonópolis	-16,45	-54,57	269	15,24536	0,353631	0,625716	0,221272	p
São José do Rio Claro (a)	-13,43	-56,72	337	8,539198	0,464455	0,650735	0,302237	p
São Vicente	-15,82	-55,42	816	34,84319	0,262805	0,755152	0,198457	p
Sorriso	-12,55	-55,72	366	43,81677	0,217712	0,755103	0,164395	p
Tangará da Serra	-14,65	-57,42	456	3,050143	0,161018	0,760203	0,122407	p

(C) classificação: (b) bom, (m) mediano, (r) ruim, (mr) muito ruim e (p) péssimo.

Tabela 4 - Índices de validação e classificação (c) do modelo de probabilidade diária de não chover

Estação	Lat	Long	Alt	Erp	r ²	D	c	C
Alta Floresta	-9,86	-56,1	267	0,958986	0,354679	0,824699	0,292503	P
Aragarças	-15,9	-52,23	308	1,518232	0,854209	0,560651	0,478913	mr
Cáceres	-16,05	-57,68	123	0,868211	0,563819	0,754333	0,425307	mr
Campos Novos dos Parecis	-13,78	-57,83	507	1,859172	0,293323	0,871488	0,255627	p
Canaranã	-13,5	-52,5	332	0,601656	0,692833	0,678586	0,470147	mr
Cuiabá	-15,55	-56,12	186	1,783795	0,665085	0,711425	0,473159	mr
Cuiabá (a)	-15,62	-56,1	150	1,751905	0,670865	0,705195	0,473091	mr
Diamantino	-14,4	-56,45	268	2,202781	0,782354	0,682186	0,533711	r
Gleba Celeste	-12,2	-56,5	321	2,671622	0,826257	0,661111	0,546248	r
Matupá	-10,25	-54,92	264	0,848927	0,585364	0,724904	0,424333	mr
Nova Xavantina	-14,7	-52,35	309	0,396057	0,740993	0,642865	0,476359	mr
Poxoréo	-15,83	-54,38	334	1,276964	0,747085	0,648707	0,484639	mr
Rondonópolis	-16,45	-54,57	269	1,739727	0,545298	0,770485	0,420144	mr
São José do Rio Claro (a)	-13,43	-56,72	337	0,803494	0,563961	0,734237	0,414081	mr
São Vicente	-15,82	-55,42	816	3,456974	0,461767	0,836814	0,386413	p
Sorriso	-12,55	-55,72	366	2,54841	0,271268	0,867729	0,235387	p
Tangará da Serra	-14,65	-57,42	456	2,924126	0,396411	0,85692	0,339693	p

(c) classificação: (b) bom, (m) mediano, (r) ruim, (mr) muito ruim e (p) péssimo.

4.2.1.1 Alta Floresta

Figura 6 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 7 - Distribuição linear da Precipitação média diária observada X estimada -validação do modelo

Figura 8 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 6, 7 e 8 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Alta Floresta. A correlação neste município foi baixa devido à distância que esta estação se encontra das outras usadas na regressão, fato que diminui a representatividade do dado estimado na região.

4.2.1.2 Aragarça

Figura 9 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 10 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 11 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 9, 10 e 11 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Aragarça. Nesse município houve boa correlação em todos os parâmetros, inclusive para a precipitação, tendo em vista as limitações de sua estimativa diária. A probabilidade de não chover para este município teve melhor desempenho na estimativa, já que apresentava série histórica maior, em relação aos outros municípios.

4.2.1.3 Cáceres

Figura 12 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 13 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 14 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 12, 13 e 14 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover em Cáceres. Esse município está localizado no sudoeste do Mato Grosso, destacado da região que concentra a maior parte das estações meteorológicas do estado. Mesmo assim, apresentou correlações razoáveis para a temperatura. A precipitação e a probabilidade de chover tiveram desempenho razoável, levando em consideração a dificuldade na estimativa da precipitação.

4.2.1.4 Campos Novos dos Parecis

Figura 15 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 16 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 17 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 15, 16 e 17 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover em Campos Novos dos Parecis. O município é localizado a oeste do Mato Grosso. A estação meteorológica do local possuía série histórica pequena, sendo a última estação do lado oeste do estado. A sua localização torna e a quantidade de dados disponíveis torna compreensível o baixo desempenho do modelo para a região.

4.2.1.5 Canaranã

Figura 18 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 19 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 20 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 18, 19 e 20 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Canaranã. Esse município está localizado na parte leste do estado do Mato Grosso, sendo a última estação meteorológica ao nordeste. A série histórica é baixa, o que explica o menor desempenho do modelo nessa localidade.

4.2.1.6 Cuiabá

Figura 21 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 22 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 23 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 21, 22 e 23 mostram o resultado das correlações lineares entre as séries sintéticas da estação convencional e observadas de temperatura, precipitação e probabilidade de não chover no município de Cuiabá. A capital do Mato Grosso conta com boa base de dados climáticos, no entanto, só a temperatura apresentou bons resultados. Isso ocorre devido às dificuldades em determinar sequências de chuva diária.

4.2.1.7 Cuiabá (estação automática)

Figura 24 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 25 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 26 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 24, 25 e 26 mostram o resultado das correlações lineares entre as séries sintéticas da estação automática e observadas de temperatura, precipitação e probabilidade de não chover no município de Cuiabá. É interessante notar a correlação dos dados estimados com a estação do item anterior. A estação convencional obteve correlação de temperatura muito superior à estação automática. Ambas foram confrontadas com a mesma série sintética, que foi gerada a partir da composição das duas. A estação automática possui série histórica cerca de oito vezes menor em relação à convencional. Já os dados de precipitação foram gerados com quantidade de estações meteorológicas muito maior. A principal restrição do banco de dados de chuva é a quantidade de estações meteorológicas com série histórica muito curta, fato que comprometeu a análise de regressão com as coordenadas e a altitude.

4.2.1.8 Diamantino

Figura 27 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 28 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 29 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 27, 28 e 29 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Diamantino, localidade encontrada no centro de todas as outras estações. O desempenho do modelo para temperatura foi bom e para precipitação e probabilidade de não chover teve desempenho melhor que a maioria das localidades testadas. A base de dados possui série histórica com mais de 30 anos e está bem localizada no que se refere à regressão linear múltipla. O bom desempenho desta estação meteorológica é uma evidência que o aumento do número de estações com séries históricas longas produziriam séries sintéticas de muita qualidade.

4.2.1.9 Gleba Celeste

Figura 30 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 31 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 32 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 30, 31 e 32 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Gleba Celeste. Este município está localizado no centro das estações hidrometeorológicas, tendo obtido desempenho razoável para valores de precipitação. Já para temperatura encontra-se na última estação no sentido noroeste das estações meteorológicas que continham dados de temperatura. O desempenho do modelo em relação às outras localidades foi bom para a precipitação e razoável para a temperatura.

4.2.1.10 Matupá

Figura 33 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 34 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 35 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 33, 34 e 35 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Matupá. Essa localidade está ao norte do estado perto de Alta Floresta. Está distante das outras estações meteorológicas, sendo o baixo desempenho do modelo para essa região esperado.

4.2.1.11 Nova Xavantina

Figura 36 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 37 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 38 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 30, 31 e 32 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Nova Xavantina. Essa localidade teve bom desempenho para temperatura e probabilidade de chover, no entanto baixo para precipitação. Isso ocorre devido à dificuldade de estimativa de dados diários de precipitação.

4.2.1.12 Poxoréo

Figura 39 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 40 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 41 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 39, 40 e 41 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Poxoréo. Essa localidade está ao sudeste do estado cercado por outras estações meteorológicas. Possui boa série histórica e obteve bom desempenho do modelo em virtude dos dois fatores beneficiando a regressão linear múltipla.

4.2.1.13 Rondonópolis

Figura 42 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 43 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 44 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 41, 42 e 43 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Rondonópolis. Essa estação está bem localizada para a regressão por estar cercada de outras estações, tendo obtido bom desempenho para estimativa de temperatura. No entanto, o baixo desempenho da precipitação, além das dificuldades em estimar dados diários de precipitação, pode ocorrer pelo fato da validação ser feita em série histórica muito curta, ou seja, pouco confiável.

4.2.1.14 São José do Rio Claro

Figura 45 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 46 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 47 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 45, 46 e 47 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de São José do Rio Claro. Está bem localizado para a regressão, tendo obtido bons resultados em relação às outras estações.

4.2.1.15 São Vicente

Figura 48 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 49 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 50 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 48, 49 e 50 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de São Vicente. Esta é uma estação localizada bem no centro das outras estações meteorológicas. O baixo desempenho do modelo nesta localidade pode estar relacionado à série histórica muito curta desta estação.

4.2.1.16 Sorriso

Figura 51 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 52 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 53 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 51, 52 e 53 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Sorriso. Este município encontra-se distante de outras estações meteorológicas e possui série histórica muito curta, comprometendo o resultado do modelo para essa região.

4.2.1.17 Tangará da Serra

Figura 54 - Distribuição linear da temperatura média diária observada X estimada - validação do modelo

Figura 55 - Distribuição linear da Precipitação média diária observada X estimada - validação do modelo

Figura 56 - Distribuição linear da Probabilidade de não chover diária observada X estimada - validação do modelo

As figuras 54, 55 e 56 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura, precipitação e probabilidade de não chover no município de Tangará da Serra. Essa estação meteorológica foi a que continha a menor série histórica de todas usadas na regressão, fato comprometedor para a validação do modelo.

4.2.2 Validação de dados mensais

Tabela 5 - Índices de validação e de classificação (c) do modelo de geração de séries de Precipitação média mensal

Estação	Lat	Long	Alt	Erp	r ²	d	c	C
Alta Floresta	-9,86	-56,1	267	1,54	0,90	0,71	0,63	m
Araguariças	-15,9	-52,23	308	2,81	0,97	0,54	0,52	r
Cáceres	-16,05	-57,68	123	1,94	0,96	0,48	0,46	mr
Campos Novos dos Parecis	-13,78	-57,83	507	5,58	0,77	0,61	0,47	mr
Canaranã	-13,5	-52,5	332	2,58	0,97	0,57	0,55	r
Cuiabá	-15,55	-56,12	186	2,52	0,89	0,51	0,45	mr
Cuiabá auto	-15,62	-56,1	150	1,93	0,80	0,42	0,34	p
Diamantino	-14,4	-56,45	268	5,63	0,92	0,66	0,61	r
Gleba Celeste	-12,2	-56,5	321	3,08	0,97	0,65	0,63	m
Matupa	-10,25	-54,92	264	0,57	0,90	0,62	0,56	r
Nova Xavantina	-14,7	-52,35	309	1,71	0,95	0,50	0,47	mr
Poxoréo	-15,83	-54,38	334	3,36	0,92	0,63	0,58	r
Rondonópolis	-16,45	-54,57	269	2,75	0,91	0,50	0,45	mr
São José do Rio Claro au	-13,43	-56,72	337	9,33	0,94	0,48	0,45	mr
São Vicente	-15,82	-55,42	816	7,12	0,69	0,72	0,50	mr
Sorriso	-12,55	-55,72	366	7,90	0,91	0,57	0,52	r
Tangará da serra	-14,65	-57,42	456	1,15	0,67	0,70	0,47	mr

classificação: (o) ótimo, (b) bom, (m) mediano, (r) ruim, (mr) muito ruim e (p) péssimo

Tabela 6 - Índices de validação e de classificação (c) do modelo de geração de séries de temperatura média mensal

Estação	Lat	Long	Alt	Erp	r^2	d	c	C
Alta Floresta	-9,86	-56,1	267	0,08412	0,8047	0,937719	0,754582	mb
Aragarças	-15,9	-52,23	308	2,351026	0,988373	0,881079	0,870834	O
Cáceres	-16,05	-57,68	123	0,823175	0,990498	0,83284	0,824926	mb
Campos Novos dos Parecis	-13,78	-57,83	507	0,006591	0,938025	0,858378	0,80518	mr
Canaranã	-13,5	-52,5	332	2,158368	0,8236	0,937957	0,772501	mb
Cuiabá	-15,55	-56,12	186	1,935338	0,9949	0,860873	0,856482	o
Cuiabá(a)	-15,62	-56,1	150	3,673894	0,948922	0,862453	0,818401	mb
Diamantino	-14,4	-56,45	268	1,464359	0,987268	0,880998	0,869781	o
Gleba Celeste	-12,2	-56,5	321	2,976666	0,771106	0,873467	0,673535	b
Matupá	-10,25	-54,92	264	0,818729	0,878427	0,97375	0,855368	o
Nova Xavantina	-14,7	-52,35	309	0,610841	0,978547	0,868426	0,849795	mb
Poxoréo	-15,83	-54,38	334	2,165687	0,891522	0,798505	0,711885	b
Rondonópolis	-16,45	-54,57	269	0,901143	0,964542	0,863538	0,832919	mb
São José do Rio Claro(a)	-13,43	-56,72	337	0,568207	0,978047	0,900445	0,880678	o
São Vicente	-15,82	-55,42	816	10,04521	0,869525	0,780235	0,678434	b
Sorriso	-12,55	-55,72	366	2,36936	0,346612	0,96575	0,334741	p
Tangará da Serra	-14,65	-57,42	456	4,46411	0,573217	0,897317	0,514357	r

classificação: (o) ótimo, (b) bom, (m) mediano, (r) ruim, (mr) muito ruim e (p) péssimo

4.2.2.1 Alta Floresta

Figura 57 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 58 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 57 e 58 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Alta Floresta. Percebe-se que mesmo os municípios distantes das outras estações meteorológicas como Alta Floresta, localizado no extremo norte do estado tiveram o desempenho do modelo elevado em escala mensal.

4.2.2.2 Aragarça

Figura 59 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 60 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 59 e 60 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Aragarças. Esse município obteve desempenho do modelo em escala mensal ótimo para temperatura e muito bom para precipitação, que apesar de obter correlação linear próxima de 1, não obteve concordância necessária para ser classificado como ótimo.

4.2.2.3 Cáceres

Figura 61 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 62 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 61 e 62 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Cáceres. Também obteve desempenho do modelo alto para escala mensal.

4.2.2.4 Campos Novos dos Parecis

Figura 63 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 64 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 63 e 64 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Campos Novos dos Parecis. Este município apresentou boa confiabilidade da estimativa na escala mensal.

4.2.2.5 Canaranã

Figura 65 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 66 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 65 e 66 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Canaranã. Este município não obteve bom desempenho do modelo para temperatura em escala mensal, provavelmente devido à pouca informação meteorológica de temperatura distribuída pelo estado. Precipitação teve desempenho melhor.

4.2.2.6 Cuiabá

Figura 67 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo.

Figura 68 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 66 e 67 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Cuiabá. Cuiabá obteve desempenho excelente na estimativa de temperatura e bom para precipitação.

4.2.2.7 Diamantino

Figura 69 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 70 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 69 e 70 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Diamantino. Teve bom desempenho na estimativa de temperatura e precipitação na escala mensal.

4.2.2.8 Gleba Celeste

Figura 71 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 72 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 71 e 72 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Gleba Celeste. Esse município não teve o desempenho de outras localidades na estimativa de temperatura, apesar de classificado como bom. Precipitação teve desempenho do modelo classificado como muito bom.

4.2.2.9 Matupá

Figura 73 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 74 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 73 e 74 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Matupá. O desempenho da modelagem para essa localidade também obteve boa confiabilidade em escala mensal.

4.2.2.10 Nova Xavantina

Figura 75 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 76 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 75 e 76 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Nova Xavantina. Este município também obteve bom desempenho da modelagem em escala mensal.

4.2.2.11 Poxoréo

Figura 77 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 78 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 77 e 78 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Poxoréo. Neste município o desempenho da modelagem foi bom para temperatura e precipitação.

4.2.2.12 Rondonópolis

Figura 79 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 80 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 79 e 80 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Rondonópolis. Este município também teve bom desempenho na estimativa de temperatura e precipitação.

4.2.2.13 São José do Rio Claro

Figura 81 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 82 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 81 e 82 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de São José do Rio Claro. Município com bom desempenho da modelagem para temperatura e precipitação.

4.2.2.14 São Vicente

Figura 83 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 84 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 83 e 84 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de São Vicente. São Vicente não teve bom desempenho para precipitação, já a temperatura teve desempenho razoável.

4.2.2.15 Sorriso

Figura 85 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 86 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 85 e 86 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Sorriso. Sorriso teve desempenho péssimo para a estimativa de temperatura, provavelmente por estar distante das outras estações meteorológicas. A quantidade de estações com boa base de dados era muito pequena.

4.2.2.16 Tangará da Serra

Figura 87 - Distribuição linear da Temperatura média mensal observada X estimada - validação do modelo

Figura 88 - Distribuição linear da Precipitação média mensal observada X estimada - validação do modelo

As figuras 87 e 88 mostram o resultado das correlações lineares entre as séries sintéticas e observadas de temperatura e precipitação mensal para o município de Tangará da Serra. Apesar de ser uma localidade próxima às outras estações meteorológicas, teve baixo desempenho da modelagem para temperatura. Precipitação também não apresentou boa correlação entre os dados estimados e observados.

4.3 Determinação da capacidade de armazenamento de água (CAD)

Figura 89 - Mapa de classes de argila obtido por krigagem

Figura 90 - Semivariograma mostrando o modelo usado na krigagem de argila

Figura 91 - Mapa de classes de silte obtido por krigagem

Figura 92 - Semivariograma mostrando o modelo usado na krigagem de silte

Figura 93 - Mapa de classes de areia obtido pela diferença do total subtraído silte + argila

Figura 94 - Mapa de classes do teor de matéria orgânica obtido por krigagem

Figura 95 - Semivariograma mostrando o modelo usado na krigagem de argila

Figura 96- Mapa de classes da capacidade de armazenamento de água (CAD) obtido por pedotransferência

A figura 89 mostra o mapa classificado de argila obtido por krigagem. A figura 90 mostra o semivariograma e o modelo ajustado referente a essa krigagem. A interpolação geoestatística foi feita usando o pacote geoR do software estatístico R. Foi ajustado o modelo mais representativo para a interpolação. A figura 91 mostra o mapa classificado de silte e a figura 92 o semivariograma e o modelo ajustado referente à essa krigagem. O mapa de areia (figura 93) vem da substituição do total subtraindo silte+argila ($\text{areia} = 100 - (\text{silte} + \text{argila})$). A figura 94 mostra o mapa classificado de matéria orgânica com método similar aos outros parâmetros. A figura 95 é o semivariograma com o modelo ajustado referente à essa krigagem.

A figura 96 é o mapa de capacidade de água disponível (CAD) obtido através da pedotransferência. O conteúdo volumétrico residual (θ_r) obtido por pedotransferência foi muito próximo do conteúdo volumétrico no ponto de murcha permanente (θ_{pmp} a -15kPa). Dessa forma, pode-se considerar o θ_r como o menor conteúdo a ser utilizado na determinação da CAD. A CAD no estado do Mato Grosso variou em torno de 100mm que é um valor geralmente usado em balanços hídricos regionais. A importância desse modelo foi levar em consideração as variações edáficas responsáveis pelo armazenamento de água no solo. Com isso, cada localidade teve seu balanço hídrico calculado com a CAD específica do local.

Nas figuras 97 a 108 dos próximos itens são apresentados os parâmetros do balanço hídrico calculado com todo o banco de dados estimado gerado para esta dissertação.

4.4 Balanço hídrico normal mensal

Figura 97 - Mapa de classes de precipitação mensal estimada

A figura 97 mostra o mapa das médias mensais de precipitação obtido das séries sintéticas de toda localidade do estado do Mato Grosso. Nota-se grande período com ausência de chuva, que estende-se de maio a setembro. A região norte do estado apresentou valores de chuva maiores, mostrando ser uma região com alta pluviosidade concentrada no período de novembro a março. A região central do estado mostrou alta pluviosidade no mês de janeiro, sendo o restante do período

de novembro a março com chuvas moderadas. O sul do estado registrou as menores precipitações ao longo do ano.

Figura 98 - Mapa de classes de temperatura média mensal estimada

A figura 98 mostra o mapa das médias mensais de temperatura obtido das séries sintéticas de toda localidade do estado do Mato Grosso. Nota-se altas temperaturas para o sul do estado em todo período que estende-se de setembro a março. O restante do estado segue a tendência da latitude como principal componente do gradiente de temperatura determinado pela proximidade da localidade à linha do equador.

Figura 99 - Mapa de classes de evapotranspiração potencial mensal estimada

A figura 99 mostra o mapa das médias mensais de evapotranspiração potencial obtido das séries sintéticas de toda localidade do estado do Mato Grosso. A evapotranspiração medida pelo método de Thornthwaite é diretamente proporcional ao valor de temperatura. Dessa forma, segue a mesma tendência da distribuição da temperatura média do ar ao longo do estado.

Figura 100 - Mapa de classes de evapotranspiração real mensal estimada

A figura 100 mostra o mapa das médias mensais de evapotranspiração real obtido das séries sintéticas de toda localidade do estado do Mato Grosso. Este mapa já evidencia a combinação da precipitação com a temperatura. O sul do estado possui altas temperaturas no mês de outubro, no entanto não consegue alcançar o potencial da evapotranspiração devido aos baixos índices pluviométricos registrados no mês. Já a região norte possui evapotranspiração real sempre próxima ao potencial do período, já que os índices pluviométricos permitem que a planta fotossintetize em seu potencial máximo.

Figura 101 - Mapa de classes de excedente hídrico mensal estimado

A figura 101 mostra o mapa das médias mensais de excedente hídrico obtido das séries sintéticas de toda localidade do estado do Mato Grosso. Percebe-se que o sul do estado possui curto período do ano apresentando excedente hídrico. Esta região do estado chamou a atenção por possuir altas taxas de evapotranspiração com baixa precipitação. Além disso, esta região possui solos com baixa CAD, sendo também responsável pela baixo excedente hídrico registrado.

Figura 102 - Mapa de classes de deficiência hídrica mensal estimada

A figura 102 mostra o mapa das médias mensais de deficiência hídrica obtido das séries sintéticas de toda localidade do estado do Mato Grosso. Concordando com o resultado do excedente hídrico, o sul do estado apresentou os maiores valores de deficiência hídrica ao longo do ano. A combinação da alta evapotranspiração com os baixos índices pluviométricos e a baixa capacidade de armazenamento do solo na região fazem com que esta região apresente os maiores índices de deficiência hídrica do estado.

4.5 Mapas anuais

Figura 103 - Mapa de classes de precipitação anual estimada

Figura 104 - Mapa de classes de temperatura média anual estimada

Figura 105 - Mapa de classes de evapotranspiração potencial anual estimada

Figura 106 - Mapa de classes de evapotranspiração real anual estimada

Figura 107 - Mapa de classes de excedente hídrico anual estimada

Figura 108 - Mapa de classes de deficiência hídrica anual estimada

A figura 103 mostra a distribuição das chuvas no estado, a figura 104 mostra a distribuição da temperatura, a figura 105 mostra a distribuição da evapotranspiração potencial no estado. As figuras 106, 107 e 108, que mostram a distribuição da evapotranspiração real, excedente e deficiência hídrica respectivamente, são resultados da combinação da temperatura, precipitação e capacidade de armazenamento de água no estado do Mato Grosso. Os mapas anuais seguem as mesmas tendências discutidas nos mapas mensais. Percebe-se mais claramente com os mapas anuais alguns pontos relevantes da combinação dos fatores responsáveis pela deficiência hídrica no estado do Mato Grosso. A deficiência hídrica na parte norte do estado é muito próxima ao registrado na parte oeste, apesar da evapotranspiração potencial ser maior. Os valores de precipitação das duas regiões são muito parecidos, ficando claro que a ausência de diferença no déficit hídrico das duas regiões ocorre devido à maior capacidade de retenção de água do solo na região norte do estado. A parte sul do estado registrou os menores valores de deficiência hídrica e os maiores valores de excedente hídrico, devido à menor quantidade de chuvas combinada às temperaturas elevadas.

5. CONCLUSÕES

Este trabalho contribuiu para o estado do Mato Grosso com balanços hídricos estimados para qualquer localidade. Cada coordenada geográfica passa a ter sua própria combinação de temperatura e precipitação, sendo valores específicos da coordenada geográfica. A validação do modelo mostrou alta confiabilidade da modelagem em escala mensal para a maioria das localidades testadas. Portanto, os mapas gerados de parâmetros do balanço hídrico trazem alto grau de confiabilidade, os resultados são consistentes segundo a avaliação do modelo.

A série sintética diária gerada não trouxe valores confiáveis para o cálculo de modelos de crescimento de culturas. Essa modelagem trouxe bons resultados em escala mensal, tendo gerado informações importantes para o planejamento regional do estado do Mato Grosso.

REFERÊNCIAS

- AGUILAR, D.; KRUKER, R.; CALHEIROS, R.E.A. **Determinação da evapotranspiração potencial e balanço hídrico da Região da Grande Dourados**. Dourados: EMBRAPA, UEPAE, 1986. 150 p.
- ALFONSI, R.R.; CAMARGO, M.B.P. Simulação de épocas de semeadura baseadas no atendimento da demanda hídrica para culturas de soja, milho e arroz de sequeiro no estado de São Paulo. In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, 6., 1989, Maceió. **Anais...** Maceió: Sociedade Brasileira de Agrometeorologia, 1989. v. 1, p.34-38.
- ALMEIDA, R.M.B. **Características climatológicas do regime de chuva em Minas Gerais**. 1995. 64 p.Dissertação (Mestrado em Meteorologia Agrícola) - Universidade Federal de Viçosa, Viçosa, 1995.
- AMORIM, R.S.S. **Avaliação dos modelos de predição hídrica USLE, RUSLE e WEPP para condições edafoclimáticas brasileiras**. 2004. 120 p.Tese (Doutorado em Meteorologia Agrícola) - Universidade Federal de Viçosa, Viçosa, 2004.
- ARRUDA, F.; ZULLO JÚNIOR, J. ; OLIVEIRA, J.B. Parâmetros de solo para o cálculo da água disponível com base na textura do solo. **Revista Brasileira de Ciência do Solo**, Campinas, v. 11, n. 1, p. 11-15, 1987.
- ASSAD, M.L.L.; ASSAD, E.D.; EVANGELHISTA, B.A. Chuvas extremas na região dos cerrados. In: ASSAD, C.D. (Coord.). **Chuva no cerrado: análise e espacialização**. Brasília: EMBRAPA, CPAC, 1994. p. 49-54.
- BAENA, L.G.N. **Modelo para geração de séries sintéticas de dados climáticos**. 2004. 154 p.Tese (Doutorado em Engenharia Agrícola) - Universidade Federal de Viçosa, Viçosa, 2004.
- BEGA, R.; VIEIRA, S.; MARIA, I.; DECHEN, S.; CASTRO, O. Variabilidade espacial das precipitações pluviais diárias em uma estação experimental, em Pindorama, SP. **Bragantia**, Campinas, v. 64, p. 149-156, 2005.
- BERG, M.V.D.; KLAMT, E.; REEUWIJK, L.V. Pedotransfer functions for the estimation of moisture and retention characteristics of ferralsols and related soils. **Geoderma**, Amsterdam, v. 78, p. 161-180, 1997.
- BERNER, P.M.; VIEIRA, S.; LIMA, E.; ANJOS, L. Variabilidade espacial de propriedades físicas e químicas de um Cambissolo sob dois sistemas de manejo de cana-de-açúcar. **Revista Brasileira de Ciência do Solo**, Campinas, v. 31, p. 837-844, 2007.
- BOUMA, J. Using soil survey data for quantitative land evaluation. **Advances in Soil Sciences**, New York, v. 9, p. 177-213, 1989.

BURIOL, G.; ESTEFANEL, V.; FERREIRA, M.; PINTO, H. Estimativa das médias das temperaturas máximas mensais e anuais do estado do rio grande do sul. **Revista do Centro de Ciências Rurais**, Santa Maria, v. 3, p. 131-150, 1973.

BURROUGH, P. Soil variability: a late 20th century view. **Soils and Fertilizers**, Wallingford, v. 56, p. 529-562, 1993.

CAMARGO A.P.; SENTELHAS, P. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 5, p. 89-97, 1997.

CAMARGO, E.; FELGUEIRAS, C.; MONTEIRO, A. A importância da modelagem da anisotropia na distribuição espacial de variáveis ambientais utilizando procedimentos geoestatísticos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10., 2001, Foz do Iguaçu. Disponível em: <www.dpi.inpe.br/carlos/trabcientif.htm>. Acesso em: 09 out. 2007.

CAMARGO, E.C.G. **Desenvolvimento, implementação e teste de procedimentos geoestatísticos (krigagem) no sistema de processamento de informações georreferenciadas (Spring)**. 1997. 123 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1997.

CARDIM, M. **Mapeamento do comportamento multivariado das principais variáveis climáticas de interesse agrícola do Estado de São Paulo**. 2001. 124 p. Tese (Doutorado em Matemática) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 2001.

CARGNELUTTI FILHO, A.C.; MALUF, J.; MATZENAUER, R.; STOLZ, A. Altitude e coordenadas geográficas na estimativa da temperatura mínima média decendial do ar no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, Brasília, v. 41, n. 6, p.893-901, jun. 2006.

CARVALHO, J.R.P.; ASSAD, E. Análise espacial da precipitação pluviométrica no estado de São Paulo: comparação de interpoladores. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 32., 2003, Goiânia. **Anais...** Goiânia: SBEA, 2003. p. 37-42.

CARVALHO, J.D.; SILVEIRA, P.D.; VIEIRA, S.R. Geoestatística na determinação da variabilidade espacial de características químicas do solo sob diferentes preparos. **Pesquisa Agropecuária Brasileira**, Brasília, v. 37, n. 8, p. 1151-1159, 2002.

CECÍLIO, R.A.; RODRIGUEZ, R.D.G.; BAENA, L.G.N.; OLIVEIRA, F.G. Analysis of the RUSLE and WEPP models for a small watershed located in Viçosa, Minas Gerais State, Brazil. INTERNATIONAL SOIL CONSERVATION ORGANIZATION CONFERENCE, 13., 2004, Brisbane. **Proceedings...** Brisbane: ISCOC, 2004. p. 237-253,

CLARK, I. **Practical geostatistics**. London: Applied Science, 1979. 130 p.

COELHO, D.; SEDIYAMA, G.; VIEIRA, M. Estimativa das temperaturas médias mensais e anual no estado de minas gerais. **Revista Ceres**, Viçosa, v. 20, p. 455-459, 1973.

DILLON, W.; GOLDSTEIN, M.E. **Multivariate analysis: methods and applications**. New York: Wiley, 1984. 608p.

DOURADO-NETO D.; JONG VAN LIER, Q. **Programa para elaboração do balanço hídrico para culturas anuais e perenes**. Piracicaba : ESALQ, Departamento de Agricultura, 1991. 58 p.

DRAPER N.R.; SMITH, R. **Applied regression analysis**. 3rd ed. New York: Wiley, 1996. 706 p.

ESTEFANEL, V.; FERREIRA, M.; BURIOL, G.A.; PINTO, H.S. Estimativa das médias das temperaturas mínimas mensais e anuais do Estado do Rio Grande do Sul. **Revista do Centro Ciências Rurais**, Santa Maria v. 3, p. 1-20, 1973.

FANCELLI, A.; LIMA, U. **Milho: produção, pré-processamento e transformação agroindustrial**. São Paulo: Secretaria de Indústria, Comércio, Ciência e Tecnologia, 1983. 112 p. (Série Agroindustrial, 5).

FEITOZA, L.; SCÁRDUA, J.; SEDIYAMA, G.; VALLE, S. Estimativas das temperaturas médias das máximas mensais e anual do Estado do Espírito Santo. **Revista do Centro Ciências Rurais**, Santa Maria, v. 10, p. 25-32, 1980a.

_____. Estimativas das temperaturas médias das mínimas mensais e anual do Estado do Espírito Santo. **Revista do Centro Ciências Rurais**, Santa Maria , v.10, p.15-24, 1980b.

FRIEND, A.A. process-based terrestrial biosphere model of ecosystem dynamics. **Ecological Modelling**, Kassel, v. 95, p. 249-287, 1997.

GENUCHTEN, M. van. A closed form equation for predicting the hydraulic conductivity of unsaturated soils. **Soil Science Society of America Journal**, Madison, v. 44, p. 892-898, 1980.

GOMES, B.M. **Comportamento espacial do percentil 75 da precipitação decendial do Estado de São Paulo**. 2001.101 p. Tese (Doutorado em Irrigação) - Faculdade de Ciências Agronômicas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 2001.

GOMES, F. **Curso de estatística experimental**. 4. ed. São Paulo: Nobel, 1970. 456 p.

GOMES, N.; FARIA, M.; SILVA, A.; MELLO, C.; VIOLA, M. Variabilidade espacial de atributos físicos do solo associados ao uso e ocupação da paisagem. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 11, n. 14, p. 427-435, 2007.

GUIMARÃES, E. C. ; OLIVEIRA, J. A. ; TAVARES, M. . Comportamento espacial de chuvas de verão no estado de Minas Gerais. In: SIMPÓSIO DE ESTATÍSTICA APLICADA À EXPERIMENTAÇÃO AGRONÔMICA, 11., 2005, Londrina. **Anais...** Londrina: RBRAS, 2005. v. 1. p. 1-5.

GRIME, J.; HUNT, R. Relative growth rate: its range and adaptative significance in a local flora. **Journal of Ecology**, Londres, v. 63, p. 393-422, 1975.

GUENNI, L. Seasonal changes in inter-relationships between climatic variables. **Agriculture and Forest Meteorology**, Amsterdam, v. 53, p. 45-58, 1990.

HE, C. Modeling hydrologic impact of withdrawing the great lakes water for agricultural irrigation. **Journal of the American Water Resources Association**, Herndon, v. 33, p. 1055-1068, 1997.

HILLEL, D. **Environmental soil physics**. Massachusetts: Academic Press, 1998. 771 p.

HOFFMANN R.; VIEIRA, S. **Análise de regressão: uma introdução á econometria**. 3. ed. São Paulo: HUCITEC; EDUSP, 1998. 379 p.

JONES, J.; COLWICK, R.; THREADGILL, E. A simulated environmental model of temperature, evaporation, rainfall and soil moisture. **Transactions of the ASAE**, St. Joseph, v. 15, p. 366-372, 1972.

JOURNAL, A.G.; HUIJBREGTS, C. **Mining geoestistics**. London: Academic Press, 1991. 600 p.

KITTEL, T. The VEMAP integrated database for modeling united states ecosystem/vegetation sensitivity to climate change. **Journal of Biogeography**, Sidney, v. 2, p. 857-862, 1995.

KRIGE, D.G. A statistical approach to some basic mine valuation problems on the witwatersrand. **Journal of Chemical, Metallurgical and Mining Society of South Africa**, Petroria, v. 52, n. 6, p. 119-139, 1951.

LAMBERS, H.; III, F. C.; PONS, T. **Plant physiological ecology**. New York: Springer, 1998. 540p.

LARCHER, W. **Ecofisiologia vegetal**. São Paulo: Editora Pedagógica e Universitária, 1986. 319p.

LARSEN G.A.; PENSE, R. Stochastic simulation of daily climatic data for agronomic models. **Agronomy Journal**, Madison, v. 74, p. 510-514, 1982.

LIBARDI, P.L.; PREVEDELLO, C.L.; PAULETTO, E.A.; MORAES, S.O. Variabilidade espacial da umidade, textura e densidade de partículas ao longo de uma transeção. **Revista Brasileira de Ciência do Solo**, Campinas, v. 10, n. 2, p. 85-90, maio/ago. 1986.

LIMA, M.; RIBEIRO, V. Equações de estimativa da temperatura do ar para o estado do Piauí. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 6, p. 221-227, 1998.

MACEDO, M.D.; OLIVEIRA, J.C.D.; BARBOSA, A.M.; CÂMARA, G.; ASSAD, E.D. **Análise comparativa da espacialização do risco climático pela média ponderada, krigagem ordinária e krigagem por indicação.** São José dos Campos, INPE, 2001. Disponível em: <www.dpi.inpe.br/geopro/trabalhos/marizarisco.pdf>. Acesso em: 09 out. 2007.

MACHADO, R.V. **Variabilidade espacial de atributos físico-hídricos em uma hidroseqüência de solos bem á muito mal drenados.** 1994. 88 p. Dissertação (Mestrado em Solos e Nutrição de Plantas) - Escola Superior de Agricultura de Lavras, Lavras, 1994.

MATALAS, N. Mathematical assessment of synthetic hydrology. **Water Resources Research**, Tucson, v. 3, p. 937-945, 1967.

MATHERON, G. Principles of geostatistics. **Economic Geology**, Lancaster, v. 58, n. 8, p. 1246-1266, Dec. 1963.

MEDEIROS, S.D.S.; CECÍLIO, R.A.; MELO JÚNIOR, J.C.F.D.; SILVA JÚNIOR, J.L.C. Estimativa e espacialização das temperaturas do ar mínimas, médias e máximas na região nordeste do Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 9, p. 247-255, 2005.

MELLAART, E. **Small-scale spatial rain distribution: the effect of temporal and spatial rain distribution on drought and crop yield at village level.** Nelspruit: Institute for Soil, Climate and Water, 1999. 18 p.

MELLO, M.; PEDRO JÚNIOR, M.; LOMBARDI NETO, F. Hidrologia, Climatologia e Agrometereologia .In : BERTOLINI, D.; CARRARO, E.; LOMBARDI NETO, F.; LEPSCH, I.F.; MELLO, M.H.A.; DRUGOWICH, M.I.; PEDRO JÚNIOR, M.J. BELLINAZZI JÚNIOR, R. **Potencialidades agrícolas das terras do Estado de São Paulo.** Campinas: CATI, 1994. p. 23-41.

MENDONÇA, P.D.V. Sobre o novo método de balanço hídrico de Thornthwaite e Mather. In: CONGRESSO LUSO-ESPANHOL PARA O PROGRESSO DAS CIÊNCIAS, 24., Madri **Anais...** Madri, 1958. p. 415-425.

MORICOCHI, L.; RONCATO P.C.R.; VICENTE, J.R. Potencial de produção e produtividade da agricultura paulista: o caso do milho. **Agricultura em São Paulo**, São Paulo, v. 36, n. 1, p. 127-148, 1989.

NETER, J. **Applied linear regression models.** 3rd ed. New York: McGraw Hill, 1997. 532 p.

NEVES, R.; CHAMBEL-LEITÃO, P.; LEITÃO, P. Modelação numérica da circulação da água no solo - o modelo MOHID. **Pedologia**, Oeiras, v. 28, p. 45-55, 2000.

NICKS A.D.; HARP, J. Stochastic generation of temperature and solar radiation data. **Journal of Hydrology**, Amsterdam, v. 48, p. 1-17, 1980.

OLIVEIRA, J.A.; GUIMARÃES, E.; TAVARES, M. Comportamento espacial de chuvas de verão no estado de minas gerais. In: REUNIÃO ANUAL DA REGIÃO BRASILEIRA DA SOCIEDADE INTERNACIONAL DE BIOMETRIA, 50., 2005, Londrina. **Anais..** Londrina, 2005. 1 CD-ROM.

OLIVEIRA, S.N.D.; REIS, G.D.; REIS, M.D.G.; LEITE, H.; COSTA, J.D. Estimativa de temperaturas mínima, média e máxima do território brasileiro situado entre 16 e 24° latitude sul e 48 e 60° longitude oeste. **Engenharia na Agricultura**, Viçosa, v. 10, p. 8-17, 2002.

OLIVEIRA, V.P.S. **Modelo para geração de séries sintéticas de precipitação**. 2003. 156 p. Tese (Doutorado em Recursos Hídricos e Ambientais) - Universidade Federal de Viçosa, Viçosa, 2003.

OSTERVELD, M.; CHANG, C. Empirical relations between laboratory determinations of soil texture and moisture retention. **Canadian Agricultural Engineering**, Ottawa, v. 22, p. 149-151, 1980.

PEREIRA, A.; ANGELOCCI, L. R.; SENTELHAS, P. **Meteorologia agrícola**. Guaíba: Agropecuária, 2002. 478 p.

PEREIRA, A.R., VILLA NOVA. N.A.; SEDIYAMA. G.C. **Evapo(transpi)ração**. Piracicaba: FEALQ, 1997. 183 p.

PICKERING, N.B.; STEDINGER, J.H.D. Weather input for no point source pollution models. **Journal of Irrigation and Drainage Engineering**, New York, v. 114, p. 674-690, 1988.

RAJAGOPALAN, B.; LALL, U.A. k-nearest-neighbor simulator for daily precipitation and other weather variables. **Water Resources Research**, Tucson, v. 35, p. 3089-3101, 1999.

RAWLS, W.; GISH, T.; BRAKENSIEK, D. Estimating soil water retention from soil physical properties and characteristics. **Advances in Soil Sciences**, New York, v. 16, p. 213-234, 1991.

REICHARDT, K. **A água em sistemas agrícolas**. São Paulo: Manoele, 1990. 188p.

REICHARDT, K.; VIEIRA, S.L.P. Variabilidade especial de solos e experimentação de campo. **Revista Brasileira de Ciência do Solo**, Campinas, v. 10, n.1, p. 1-6, jan./abr. 1986.

REIS, M.H.D.; GRIEBELER, N.P.; OLIVEIRA, L.F.C.D.; OLIVEIRA, J.D.M. Espacialização de dados de precipitação e avaliação de interpoladores para projetos de drenagem agrícola no estado de Goiás e Distrito Federal. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 4., 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. Disponível em: <marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.20.04.36/doc/229.pdf>. Acesso em: 09 out. 2007.

RICHARDSON, C. Stochastic simulation of daily precipitation, temperature and solar radiation. **Water Resources Research**, Tucson, v. 17, p. 182-190, 1981.

_____. A wind simulation model for wind erosion estimation. n. 82-2576 mi 49085. 1982. **Transactions of the ASAE**, St. Joseph, v. 49, p. 2576-2582, 1982.

_____. **WGEN: a model for generating daily weather variables.** Washington: USDA, Agricultural Research Service, 1984. 83 p. (Bulletin, 8).

ROLIM, G.; SENTELHAS, P.C.; BARBIERI, V. Planilhas no ambiente Excel para os cálculos de balanços hídricos: normal, seqüencial, de cultura e de produtividade real e potencial. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 6, p. 133-137, 1998.

ROMANI, L.; SANTOS, E.D.; EVANGELISTA, S.; ASSAD, E.; PINTO, H. Utilização de estações vizinhas para estimativa de temperatura e precipitação usando o inverso do quadrado da distância. In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, 13., 2003, Santa Maria. **Anais...** Disponível em: <<http://www.agritempo.gov.br/modules.php?name=Downloads&op=getit&id=23>>. Acesso em: 08 dez. 2007.

SANTOS, G.; CAMARGO. **A água em sistemas agrícolas.** Porto Alegre: Gênese Edições, 1999. 508 p.

SAXTON, K.; RAWLS, W.; ROMBERGER, J. Estimating generalized soil-water characteristics from texture. **Soil Science Society of America Journal**, Madison, v. 50, n. 4 p. 1031-1036, 1986.

SEDIYAMA, G.; MELO JÚNIOR, J. Modelos para estimativa das temperaturas normais mensais médias, máximas, mínimas e anual no estado de minas gerais. **Engenharia na Agricultura**, Viçosa, v. 6, p. 57-61, 1998.

SENTELHAS, P.; PEREIRA, A.; ANGELOCCI, L. **Meteorologia agrícola.** Piracicaba: ESALQ, 1998. 131 p.

SILVA, A.; LIBARDI, P.; VIEIRA, S. Variabilidade espacial da resistência á penetração de um Latossolo vermelho-escuro ao longo de uma transeção. **Revista Brasileira de Ciência do Solo**, Campinas, v. 13, n. 1, p. 1-5, jan./abr. 1989.

SILVA, A.P. **Variabilidade espacial de atributos físicos do solo.** 1988. 91 p. Tese (Doutorado em Solos e Nutrição de Plantas) - Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo., Piracicaba, 1988.

SILVA, J.; ÁLVARO, M.P.A. **Estimação da temperatura média do ar em Portugal Continental:** teste e comparação de métodos de interpolação em sistemas de informação geográfica. 2005. 135p. Dissertação (Mestrado em Sistema de Informação Geográfica) - Instituto Superior Técnico, Lisboa , 2005.

SILVA, J.W.; GUIMARÃES, E.C.; TAVARES, M. Variabilidade temporal da precipitação mensal e anual na estação climatológica de uberaba-mg. **Ciência e Agrotecnologia**, Lavras, v. 27, n. 3, p. 665-674, 2003.

SOUZA, G. **Introdução aos modelos de regressão linear e não-linear.** Brasília: Embrapa, SPI, 1998. 505 p.

SOUZA, L.C. **Variabilidade espacial da salinidade de um solo aluvial no semi-árido paraibano**. 1999. 77 p. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal da Paraíba, Campina Grande, 1999.

STERN R.D.; DENNETT, M.D.I. Analyzing daily rainfall measurements to give agronomically useful results. ii. a modeling approach. **Experimental Agriculture**, London, v. 18, p. 237-253, 1982.

THORNTHWAITE, C.W. An approach towards a rational classification of climate. **Geographical Review**, London, v. 38, p. 55-94, 1948.

THORNTHWAITE, C.W.; MATHER, J. The water balance. **Publications in Climatology**, Centreton, v. 10, n. 3, p. 311, 1957.

TOMASELLA J., HODNETT, M. G.; ROSSATO, L. Pedotransfer functions for the estimation of soil water retention in Brazilian soils. **Soil Science Society of America Journal**, Madison, v. 1, n. 2, p. 327-338, 2000.

VENDRUSCULO, L.; CARVALHO, J.; VIEIRA, S. Uso do software GEOEST para análise espacial da precipitação pluvial anual no estado de São Paulo. In: CONGRESSO BRASILEIRO DA SOCIEDADE BRASILEIRA DE INFORMÁTICA APLICADA Á AGROPECUÁRIA E Á AGROINDÚSTRIA, 4., 2003, Porto Seguro. **Anais...** Porto Seguro, SBIAGRO, 2003. v. 2, p.1-5.

VERONESE, D.O.; GUIMARÃES, E.C. Análise geoestatística da temperatura média de Uberaba, MG, nas quatro estações do ano. **Ciência e Engenharia**, Uberlândia, v. 11, n. 2, p. 21-26, 2002.

VIANA, T.D.A.; ARAÚJO, W. F.; ANDRADE JÚNIOR, A. S.; AZEVEDO, B.; CRISÓSTOMO JÚNIOR, R.R. Análise estocástica da ocorrência de períodos secos e chuvosos para o município Cedro, Rio de Janeiro. In: XI CONGRESSO BRASILEIRO DE METEOROLOGIA, 11., 2000, Rio de Janeiro **Anais...** Sociedade Brasileira de Meteorologia, p. 8.

VIEIRA, S. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAIS, R.F. de; ALVAREZ, V.H.; SCHAEFER, C.E.G.R. (Ed.). **Tópicos em ciência do solo**. Viçosa: Sociedade Brasileira de Ciência do Solo, 2000. v. 1, p.1-54.

VIEIRA, S.; NIELSEN, D.R.; BIGGAR, J. Spatial variability of field measured infiltration rate. **Soil Science Society of America Journal**, Madison, v. 45, n. 6, p. 1040-1048, Nov./Dec.1981.

VIEIRA, S.R.; LOMBARDI NETO, F; BURROWS, I.T. Mapeamento da chuva diária máxima provável para o estado de São Paulo. **Revista Brasileira de Ciência do Solo**, Campinas, v. 15, n. 1, p. 93-98, 1991.

VIRGENS FILHO, J.S. **Modelo computacional para simulação de dados climáticos**. 1997. 86 p.Dissertação (Mestrado em Energia na Agricultura) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 1997.

_____. **Avaliação dos modelos de predição hídrica USLE, RUSLE e WEPP para condições edafoclimáticas brasileiras.** 2001. 92 p. Tese (Doutorado em Energia na Agricultura) - Faculdade de Ciências Agronômicas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 2001.

WACKERNAGEL, H. **Multivariate geostatistics: an introduction with applications.** Berlin: Springer, 1998. 408p.

WEBSTER, R. Automatic soil boundary location for transect data. **Mathematical Geology**, Montreal, v. 5, n. 1, p. 27-37, 1973.

WILKS, D. Adapting stochastic weather generation algorithms for climate change studies. **Climatic Change**, Stanford, v. 22, p. 67-84, 1992.

_____. Simultaneous stochastic simulation of daily precipitation, temperature and solar radiation at multiple sites in complex terrain. **Agricultural and Forest Meteorology**, New Haven, v. 96, p. 85-101, 1999.

WILLIAMS, J.; PREBBLE, E.; WILLIAMS, W. The influence of texture, structure and clay mineralogy on the soil moisture characteristic. **Australian Journal Soil Research**, Melbourne, v. 21, n. 1, p. 15-31, 1983.

WILLMOTT, C. On the validation of models. **Physical Geography**, Kelowna, v. 2, p. 184-194, 1981.

ZAMBOTI, J.L. **Mapas pluviométricos médios mensais no verão para o Estado do Paraná, utilizando métodos geoestatísticos.** 2001. 117 p. Tese (Doutorado em Energia na Agricultura) - Faculdade de Ciências Agronômicas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 2001.

ZANETTI, S.S. **Modelo computacional para geração de séries sintéticas de precipitação e do seu período instantâneo.** 2003. 71 p. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal de Viçosa, Viçosa, 2003.