

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

**Modelo estocástico para estimação da produtividade de soja no Estado de São
Paulo utilizando simulação normal bivariada**

Thomas Newton Martin

**Tese apresentada para obtenção do título de Doutor em
Agronomia. Área de concentração: Fitotecnia**

**Piracicaba
2007**

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

Thomas Newton Martin
Engenheiro Agrônomo

**Modelo estocástico para estimação da produtividade de soja no Estado de São Paulo
utilizando simulação normal bivariada**

Orientador:
Prof. Dr. **DURVAL DOURADO NETO**

**Tese apresentada para obtenção do título de Doutor em
Agronomia. Área de concentração: Fitotecnia**

Piracicaba
2007

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

Martin, Thomas Newton

Modelo estocástico para estimação da produtividade de soja no Estado de São Paulo utilizando simulação normal bivariada / Thomas Newton Martin. - - Piracicaba, 2007.

208 p. : il.

Tese (Doutorado) - - Escola Superior de Agricultura Luiz de Queiroz, 2007.
Bibliografia.

1. Clima 2. Crescimento vegetal 3. Distribuições – Probabilidade 4. Estatística espaciais 5. Simulação – Estatística 6. Soja I. Título

CDD 633.34

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

O Colono

(...) Não ri seu moço daquele colono
Agricultor que ali vai passando
Admirado com o movimento
Desconfiado la vai tropicando
Ele não veio aqui te pedir nada
São ferramentas que ele anda comprando
Ele é digno do nosso respeito
De sol a sol vive trabalhando
Não toque fruta, não chame de grosso
Pra ti alimentar, na roça esta lutando.

Se o terno dele não esta na moda
Não é motivo pra dar gargalhada
Este colono que ali vai passando
É o brasileiro da mão calejada
Se o seu chapéu é da aba comprida
Ele comprou e não te deve nada
É um roceiro que orgulha a patria
Que colhe o fruto da terra lavrada
E se não fosse este colono forte
Tu ias ter que pegar na enchada.

E se tivesse de pegar na enchada
Queria ver que mocinho moderno
Pegar na foice de um arado novi
E um machado pra cortar o cerne
E enfrentar doze horas de sol
Um verão forte tu suava o terno
Tirar o leite arancar mandioca
Em mês de julho no forte do inverno
Tuas mãozinhas finas delicada
Criava calo virava um inferno.

Este colono enfrenta tudo isto
E muito mais eu não disse a metade
Planta e colhe com suor do rosto
Pra sustentar nos aqui na cidade
Não ri seu moço mais deste colono
Vai estudar numa faculdade
Tire um dr chege la na roça
Repare la quanta dificuldade
Faça algo por nossos colonos
Que deus lhe pague por tanta bondade.

Teixeirinha

*Aos meus pais, Newton e Sonia,
Dedico*

Ofereço este trabalho à minha esposa Mireli, que encarou como suas as minhas preocupações e alegrias em cada etapa dessa jornada e, principalmente, pela sua dedicação e compreensão.

AGRADECIMENTOS

A Deus, por conduzir com sabedoria o tempo de acontecimento das coisas (Ec.3.1-8).

À Escola Superior de Agricultura “Luiz de Queiroz” (Departamento de Produção Vegetal e Programa de Pós-Graduação em Fitotecnia), por proporcionar um excelente curso em nível de Doutorado.

Ao Professor Dr. Durval Dourado Neto, pela orientação, amizade e indicação dos caminhos.

Ao Professor Paulo Augusto Manfron, professor da Universidade Federal de Santa Maria, pela amizade e companheirismo.

Ao Professor Lindolfo Storck, pela amizade, pelas sugestões neste trabalho e pela presença.

Ao Pesquisador Pedro Abel Vieira Júnior, pela amizade e auxílio nesse trabalho.

Ao Professor Antonio Roberto Pereira, pelas valiosas sugestões nesse trabalho.

Ao Forschungszentrum Jülich, Alemanha, por me receber como bolsista (Programa *Sanduiche*) e proporcionar condições para o desenvolvimento deste trabalho.

Aos pesquisadores Prof. Dr. Harry Vereecken, Dr. Peter Burauel e Pós-Doutorando Mathieu Javaux, pelas contribuições para realização deste trabalho.

Ao Instituto Agrônomo de Campinas, na pessoa do Pesquisador Orivaldo Brunini, pela disponibilização dos dados.

Ao Eduardo Alvarez Santos, pelos auxílios prestados e, principalmente, pela amizade.

Aos amigos Reinaldo Bonnacarrère, Roberta Uzzo, Felipe Gustavo Pilau, Eduardo Monteiro, Ricardo Wanke e Rafael, pela amizade e companheirismo.

Aos Amigos Everaldo, Camila, Fábio, Eliane, Cibele, Jin, João Marcelo e Ariadne, pela amizade e convivência nesse período na Alemanha.

À secretária do Programa do Pós-Graduação em Fitotecnia, Luciane Lopes, pela amizade e excelente trabalho junto à secretaria de Pós-Graduação.

Aos colegas da Universidade Tecnológica Federal do Paraná (Campus Dois Vizinhos), pela amizade e convívio.

E por fim, mas não menos importante, para a minha vó Wilma e todos aqueles que torceram e acompanharam o meu trabalho de forma positiva, o meu Muito Obrigado.

SUMÁRIO

RESUMO	9
ABSTRACT	10
LISTA DE FIGURAS.....	11
LISTA DE TABELAS.....	15
1 INTRODUÇÃO	21
2 REVISÃO BIBLIOGRÁFICA.....	24
2.1 Fisiologia da produção de soja	24
2.2 Latitude, longitude e elementos do clima	26
2.2.1 Temperatura e dióxido de Carbono	27
2.2.2 Fotoperíodo	29
2.2.3 Radiação solar	32
2.2.4 Condições hídricas	33
2.3 Produtividade da cultura de soja.....	36
2.3.1 Potencial genético	36
2.3.2 Produtividade potencial	38
2.3.3 Produtividade deplecionada.....	40
2.3.4 Altas produtividades.....	42
2.4 Modelagem em agricultura.....	42
2.4.1 Modelos e modelagem.....	43
2.4.2 Aplicações da modelagem	44
2.4.3 Vantagens e limitações da modelagem	45
2.4.4 Relações entre as áreas do conhecimento	47
2.4.5 Componentes do processo de modelagem	48
2.4.6 A modelagem e a estatística	49
2.4.7 Caracterização dos elementos climáticos.....	51
2.4.8 A modelagem na cultura de soja.....	53
2.4.9 Classificação dos modelos.....	54
3 MATERIAL E MÉTODOS.....	55
3.1 Obtenção das séries históricas das variáveis climáticas	55

	8
3.2	Obtenção da radiação fotossinteticamente ativa (q) a partir da insolação 56
3.3	Aplicação do teste do Kolmogorov-Smirnov..... 57
3.3.1	Distribuições de probabilidade avaliadas..... 57
3.4	Distribuição normal bivariada 65
3.4.1	Função densidade de probabilidade da distribuição normal bivariada 66
3.4.2	Distribuição uniforme (ou retangular) 67
3.5	Verificação da homogeneidade espacial e temporal 70
3.6	Tamanho de amostra para o número de anos avaliados 71
3.7	Processos de simulação avaliados..... 72
3.7.1	Simulação de dados por intermédio da distribuição normal $\pm 1,96$ desvio padrão da média..... 72
3.7.2	Simulação de dados por intermédio da distribuição triangular assimétrica..... 73
3.7.3	Simulação de dados por intermédio da distribuição normal bivariada..... 74
3.8	Avaliação do processo de simulação bivariada..... 74
3.9	Descrição do modelo para estimação da produtividade potencial..... 77
3.10	Produtividade deplecionada..... 87
3.11	Estimação espacial e confecção de mapas 90
4	RESULTADOS E DISCUSSÃO..... 92
4.1	Considerações Finais..... 164
5	CONCLUSÕES..... 167
	REFERÊNCIAS 168
	ANEXOS..... 185

RESUMO

Modelo estocástico para estimação da produtividade de soja no Estado de São Paulo utilizando simulação normal bivariada

A disponibilidade de recursos, tanto de ordem financeira quanto de mão-de-obra, é escassa. Sendo assim, deve-se incentivar o planejamento regional que minimize a utilização de recursos. A previsão de safra por intermédio de técnicas de modelagem deve ser realizada anteriormente com base nas características regionais, indicando assim as diretrizes básicas da pesquisa, bem como o planejamento regional. Dessa forma, os objetivos deste trabalho são: (i) caracterizar as variáveis do clima por intermédio de diferentes distribuições de probabilidade; (ii) verificar a homogeneidade espacial e temporal para as variáveis do clima; (iii) utilizar a distribuição normal bivariada para simular parâmetros utilizados na estimação de produtividade da cultura de soja; e (iv) propor um modelo para estimar a ordem de magnitude da produtividade potencial (dependente da interação genótipo, temperatura, radiação fotossinteticamente ativa e fotoperíodo) e da produtividade deplecionada (dependente da produtividade potencial, da chuva e do armazenamento de água no solo) de grãos de soja, baseados nos valores diários de temperatura, insolação e chuva, para o estado de São Paulo. As variáveis utilizadas neste estudo foram: temperatura média, insolação, radiação solar fotossinteticamente ativa e precipitação pluvial, em escala diária, obtidas em 27 estações localizadas no Estado de São Paulo e seis estações localizadas em Estados vizinhos. Primeiramente, verificou-se a aderência das variáveis a cinco distribuições de probabilidade (normal, log-normal, exponencial, gama e weibull), por intermédio do teste de Kolmogorov-Smirnov. Verificou-se a homogeneidade espacial e temporal dos dados por intermédio da análise de agrupamento pelo método de Ward e estimou-se o tamanho de amostra (número de anos) para as variáveis. A geração de números aleatórios foi realizada por intermédio do método Monte Carlo. A simulação dos dados de radiação fotossinteticamente ativa e temperatura foram realizadas por intermédio de três casos (i) distribuição triangular assimétrica (ii) distribuição normal truncada a 1,96 desvio padrão da média e (iii) distribuição normal bivariada. Os dados simulados foram avaliados por intermédio do teste de homogeneidade de variância de Bartlett e do teste F, teste t, índice de concordância de Willmott, coeficiente angular da reta, o índice de desempenho de Camargo (C) e aderência à distribuição normal (univariada). O modelo utilizado para calcular a produtividade potencial da cultura de soja foi desenvolvido com base no modelo de De Wit, incluindo contribuições de Van Heenst, Driessen, Konijn, de Vries, dentre outros. O cálculo da produtividade deplecionada foi dependente da evapotranspiração potencial, da cultura e real e coeficiente de sensibilidade a deficiência hídrica. Os dados de precipitação pluvial foram amostrados por intermédio da distribuição normal. Sendo assim, a produção diária de carboidrato foi deplecionada em função do estresse hídrico e número de horas diárias de insolação. A interpolação dos dados, de modo a englobar todo o Estado de São Paulo, foi realizada por intermédio do método da Krigagem. Foi verificado que a maior parte das variáveis segue a distribuição normal de probabilidade. Além disso, as variáveis apresentam variabilidade espacial e temporal e o número de anos necessários (tamanho de amostra) para cada uma delas é bastante variável. A simulação utilizando a distribuição normal bivariada é a mais apropriada por representar melhor as variáveis do clima. E o modelo de estimação das produtividades potencial e deplecionada para a cultura de soja produz resultados coerentes com outros resultados obtidos na literatura.

Palavras-chave: Variáveis climáticas, distribuições de probabilidade, homogeneidade espacial e temporal, tamanho de amostra e modelo de crescimento de cultura

ABSTRACT

Stochastic model to estimate the soybean productivity in the State of São Paulo through bivaried normal simulation

The availability of resources, as much of financial order and human labor, is scarce. Therefore, it must stimulate the regional planning that minimizes the use of resources. Then, the forecast of harvests through modelling techniques must previously on the basis of be carried through the regional characteristics, thus indicating the routes of the research, as well as the regional planning. Then, the aims of this work are: (i) to characterize the climatic variables through different probability distributions; (ii) to verify the spatial and temporal homogeneity of the climatic variables; (iii) to verify the bivaried normal distribution to simulate parameters used to estimate soybean crop productivity; (iv) to propose a model of estimating the magnitude order of soybean crop potential productivity (it depends on the genotype, air temperature, photosynthetic active radiation; and photoperiod) and the depleted soybean crop productivity (it depends on the potential productivity, rainfall and soil water availability) based on daily values of temperature, insolation and rain, for the State of São Paulo. The variable used in this study had been the minimum, maximum and average air temperature, insolation, solar radiation, photosynthetic active radiation and pluvial precipitation, in daily scale, gotten in 27 stations located in the State of São Paulo and six stations located in neighboring States. First, it was verified that of seven variables in five probability distributions (normal, log-normal, exponential, gamma and weibull), through of Kolmogorov-Smirnov. The spatial and temporal verified through the analysis of grouping by Ward method and estimating the sample size (number of years) for the variable. The generation of random numbers was carried through the Monte Carlo Method. The simulation of the data of photosynthetic active radiation and temperature had been carried through three cases: (i) nonsymmetric triangular distribution (ii) normal distribution truncated at 1.96 standard deviation of the average and (iii) bivaried normal distribution. The simulated data had been evaluated through the test of homogeneity of variance of Bartlett and the F test, t test, agreement index of Willmott, angular coefficient of the straight line, the index of performance index of Camargo (C) and that of the normal distribution (univariate). The proposed model to simulate the potential productivity of soybean crop was based on the de Wit concepts, including Van Heenst, Driessen, Konijn, Vries, and others researchers. The computation of the depleted productivity was dependent of the potential, crop and real evapotranspirations and the sensitivity hydric deficiency coefficient. The insolation and pluvial precipitation data had been showed through the normal distribution. Being thus, the daily production of carbohydrate was depleted as function of hydric stress and insolation. The interpolation of the data, in order to consider the whole State of São Paulo, was carried through the Kriging method. The results were gotten that most of the variable can follow the normal distribution. Moreover, the variable presents spatial and temporal variability and the number of necessary years (sample size) for each one of them is sufficiently changeable. The simulation using the bivaried normal distribution is most appropriate for better representation of climate variable. The model of estimating potential and depleted soybean crop productivities produces coherent values with the literature results.

Key words: climatic variables, probability distributions, spatial and temporal homogeneity, sample size and crop growth model

LISTA DE FIGURAS

Figura 1 –	Distribuição espacial dos locais avaliados: Adamantina (1), Assis (2), Ataliba Leonel (3), Campinas (4), Campo Grande (5), Capão Bonito (6), Cascavel (7), Cravinhos (8), Gália (9), Guairá (10), Itararé (11), Jaú (12), José Bonifácio (13), Jundiá (14), Lavras (15), Limeira (16), Manduri (17), Matão (18), Mococa (19), Monte Alegre do Sul (20), Nova Odessa (21), Pariquera-Açu (22), Pindamonhangaba (23), Pindorama (24), Piracicaba (25), Ribeirão Preto (26), São Roque (27), Tatuí (28), Tietê (29), Ubatuba (30), Uberlândia (31), Votuporanga (32) e Londrina (33).	55
Figura 2 –	Função densidade de probabilidade normal e probabilidade acumulada.	59
Figura 3 –	Função densidade de probabilidade exponencial (a), função acumulativa (b), gráficos gerados a partir de uma simulação aleatória de 1000 valores, com média 0,79, variância 0,61 e Lambda (λ) igual a 2.	60
Figura 4 –	Função densidade de probabilidade log-normal (a), função acumulativa (b), gráficos gerados a partir de uma simulação aleatória de 1000 valores, com média 3,05, variância 18,89.....	61
Figura 5 –	Função densidade de probabilidade gama (a), função acumulativa (b) gráficos gerados a partir de uma simulação aleatória de 1000 valores, α e β igual a 5,5, com média 31,12, variância 172,99.....	62
Figura 6 –	Função densidade de probabilidade weibull (a), função acumulativa (b) gráficos gerados a partir de uma simulação aleatória de 1000 valores, α e β igual a 3,5, com média 2,67, variância 0,927.	65
Figura 7 –	Função densidade de probabilidade x e y, densidade marginal de y e x, densidade condicional y, dado $x = x_0$ e média da variável X (μ_x) e Y (μ_y). ...	67
Figura 8 –	Função densidade de probabilidade uniforme (a), função acumulativa (b). Gráficos gerados a partir de uma simulação aleatória de 1000 valores, com média 51,91, variância 752,30.....	69
Figura 9 –	Fator de redução de assimilação de dióxido de carbono para a cultura de soja em função da temperatura do ar (adaptado de HOFSTRA; HESKETH, 1969)	80
Figura 10 –	Relação funcional entre o fator f_{IAF} e o índice de área foliar (IAF, $m^2 \cdot m^{-2}$) .	81

	12
Figura 11 – Relação funcional entre o fator f_{Dr} e o desenvolvimento relativo da cultura (Dr).....	82
Figura 12 – Probabilidade de ocorrências (Po) e de não ocorrência (1-Po) de valores de chuva diária em São Paulo.	112
Figura 13 – Dendrogramas da dissimilaridades da temperatura mínima (a), máxima (b) e média (b) do ar, média mensal, entre os meses do ano e os 23 municípios do Estado de São Paulo, obtido pelo método de agrupamento de Ward, baseado na distância euclidiana média padronizada.....	139
Figura 14 – Dendrogramas da dissimilaridade das médias mensais da insolação (a), da radiação solar global (b) e da radiação fotossinteticamente ativa (c) entre os meses do ano e as 18 localidades do Estado de São Paulo.....	141
Figura 15 – Dendrogramas da dissimilaridade da precipitação pluvial, entre os meses do ano e as 18 localidades do Estado de São Paulo, obtido pelo método de agrupamento de Ward, baseado na distância euclidiana média padronizada.	143
Figura 16 – Produtividade média, mínima e máxima, durante as 36 datas de semeadura, obtidas através da simulação normal bivariada, valores referentes a 500 simulações (início)	151
Figura 17 – Isolinhas de produtividade média potencial e deplecionista para as 25 localidades, obtidas através do método de interpolação de Krigagem (início)	159
Figura 18 – Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h d^{-1}), Irradiância Solar Global ($Q_g, \text{cal cm}^{-2} \text{ dia}^{-1}$), Radiação Fotossinteticamente Ativa ($\text{Par}, \text{cal cm}^{-2} \text{ dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coletada de dados localizados nos municípios de Adamantina (a), Assis (b), Ataliba Leonel (c) e Campinas (d)....	163
Figura 19 – Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h.d^{-1}), Irradiância Solar Global ($Q_g, \text{cal.cm}^{-2}.\text{dia}^{-1}$), Radiação Fotossinteticamente Ativa ($\text{Par}, \text{cal.cm}^{-2}.\text{dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coletada de dados localizados nos municípios de Capão Bonito (a), Gália (b), Itararé (c) e Jaú (d).	189

- Figura 20 – Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h.d^{-1}), Irradiância Solar Global ($Q_g, \text{cal.cm}^{-2}.\text{dia}^{-1}$), Radiação Fotossinteticamente Ativa ($\text{Par}, \text{cal.cm}^{-2}.\text{dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coletada de dados localizados nos municípios de Jundiaí (a), Limeira (b), Mococa (c) e Monte Alegre do Sul (d)..... 190
- Figura 21 – Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h d^{-1}), Irradiância Solar Global ($Q_g, \text{cal.cm}^{-2}.\text{dia}^{-1}$), Radiação Fotossinteticamente Ativa ($\text{Par}, \text{cal.cm}^{-2}.\text{dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coletada de dados localizados nos municípios de Nova Odessa (a), Pariquera (b), Pindamonhangaba (c) e Pindorama (d)..... 191
- Figura 22 – Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h d^{-1}), Irradiância Solar Global ($Q_g, \text{cal cm}^{-2} \text{ dia}^{-1}$), Radiação Fotossinteticamente Ativa ($\text{Par}, \text{cal cm}^{-2} \text{ dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coletada de dados localizados nos municípios de Piracicaba (a), Riberão Preto (b), Tatuí (c) e Tietê (d). 192
- Figura 23 – Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h.d^{-1}), Irradiância Solar Global ($Q_g, \text{cal.cm}^{-2}.\text{dia}^{-1}$), Radiação Fotossinteticamente Ativa ($\text{Par}, \text{cal.cm}^{-2}.\text{dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coletada de dados localizados nos municípios de Votuporanga (a), Ubatuba (b), Guáira (c), Uberlândia (d)..... 193
- Figura 24 – Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h d^{-1}), Irradiância Solar Global ($Q_g, \text{cal cm}^{-2} \text{ dia}^{-1}$), Radiação Fotossinteticamente Ativa ($\text{Par}, \text{cal cm}^{-2} \text{ dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coletada de dados localizados nos municípios de Campo Grande (a), Cascavel (b), Londrina (c) e Lavras (d)..... 194
- Figura 25 – Isolinhas de temperatura mínima média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo..... 195
- Figura 26 – Isolinhas de temperatura mínima média mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo..... 196

Figura 27 – Isolinhas de temperatura máxima média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo.....	197
Figura 28 – Isolinhas de temperatura máxima média mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo.....	198
Figura 29 – Isolinhas de temperatura média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo.	199
Figura 30 – Isolinhas de temperatura média mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo.	200
Figura 31 – Isolinhas de temperatura média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo.	201
Figura 32 – Isolinhas de temperatura média mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo.	202
Figura 33 – Isolinhas de temperatura média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo.	203
Figura 34 – Isolinhas de radiação solar global mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo.	204
Figura 35 – Isolinhas de temperatura média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo.	205
Figura 36 – Isolinhas de radiação solar global mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo.	206
Figura 37 – Isolinhas da precipitação pluvial média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo.	207
Figura 38 – Isolinhas da precipitação pluvial média mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo.....	208

LISTA DE TABELAS

Tabela 1 –	Parâmetros empíricos dependentes da temperatura para o cálculo da variável auxiliar PLMX ($\text{kg}\cdot\text{ha}^{-1}\cdot\text{h}^{-1}$)	79
Tabela 2 –	Parâmetros empíricos, em função do desenvolvimento relativo da cultura de soja, da equação referente ao cálculo da alocação de fotoassimilados à raiz ($\alpha R_0, \alpha R_1, \alpha R_2, \alpha R_3$ e αR_4), haste ($\alpha H_0, \alpha H_1, \alpha H_2, \alpha H_3$ e αH_4), folha ($\alpha F_0, \alpha F_1, \alpha F_2, \alpha F_3$ e αF_4) e órgão reprodutivo ($\alpha OR_0, \alpha OR_1, \alpha OR_2, \alpha OR_3$ e αOR_4) (adaptado de DRIESSEN; KONIJN, 1992)	83
Tabela 3 –	Aspectos analisados na comparação de algoritmos, fidelidade aos dados originais (FDO), suavidade da curva (SC), velocidade de computação (VC) e precisão geral (PG), considerando 1 como melhor e 5 como pior (KRAJEWSKI; GIBBS, 1966).....	91
Tabela 4 –	Estimativa da média e desvio padrão mensal para a temperatura mínima do ar, para as estações meteorológicas localizadas em São Paulo.	96
Tabela 5 –	Estimativa da média e desvio padrão mensal para a temperatura máxima do ar, para as estações meteorológicas localizadas em São Paulo.	97
Tabela 6 –	Estimativa da média e desvio padrão mensal para a temperatura média do ar, para as estações meteorológicas localizadas em São Paulo.	98
Tabela 7 –	Estimativa da média e desvio padrão mensal para a insolação, para as estações meteorológicas localizadas em São Paulo.	99
Tabela 8 –	Estimativa da média e desvio padrão mensal para a radiação solar, para as estações meteorológicas localizadas em São Paulo.	100
Tabela 9 –	Estimativa da média e desvio padrão mensal para a radiação fotossinteticamente ativa, para as estações meteorológicas localizadas em São Paulo.	101
Tabela 10 –	Estimativa da média e desvio padrão mensal para chuva nas estações meteorológicas localizadas em São Paulo.	102

Tabela 11 – Número máximo (Max), mínimo (Min) e médio (Med) de dias do mês dentre os 23 locais observados* e total de dias do ano, que aderiram as funções de distribuições de probabilidade normal (N), exponencial (E), log-normal (LN), gama (G) e weibull (W), pelo teste de Kolmogorov-Smirnov a 5% de probabilidade de erro, para as variáveis temperatura mínima e máxima diária.....	105
Tabela 12 – Frequência máxima (Max), mínima (Min), média (Med) de dias do mês dentre os 18 locais observados* e total do número de dias do ano que aderiram as distribuições de densidade de probabilidade normal (N), exponencial (E), log-normal (LN), gama (G) e weibull (W), pelo teste de Kolmogorov-Smirnov a 5% de probabilidade de erro, para as variáveis temperatura média do ar e insolação.	106
Tabela 13 – Frequência máxima (Max), mínima (Min), média (Med) de dias do mês dentre os 18 locais observados* e total do número de dias do ano que aderiram as distribuições de densidade de probabilidade normal (N), exponencial (E), log-normal (LN), gama (G) e weibull (W), pelo teste de Kolmogorov-Smirnov a 5% de probabilidade de erro, para as variáveis radiação solar global e radiação fotossinteticamente ativa.	108
Tabela 14 – Frequência máxima (Max), mínima (Min), média (Med) de dias do mês dentre os 18 locais observados* e total do número de dias do ano que aderiram as distribuições de densidade de probabilidade normal (N), exponencial (E), log-normal (LN), gama (G) e weibull (W), pelo teste de Kolmogorov-Smirnov a 5% de probabilidade de erro, para a variável chuva..	111
Tabela 15 – Valores mínimos (Min), máximos (Máx) e médios (Med) dos parâmetros alfa e beta das distribuições de probabilidade gama e weibull, para os locais do Estado de São Paulo.	113
Tabela 16 – Parâmetros originais média (\hat{m}), desvio padrão ($\hat{\sigma}$), covariância (COV) e correlação entre a radiação fotossinteticamente ativa e temperatura média (ρ) para as variáveis radiação fotossinteticamente ativa (PAR) e temperatura média do ar (TEMP), nas 24 datas, para os 17 locais* do Estado de São Paulo.	115

- Tabela 17 – Parâmetros média (\hat{m}), desvio padrão ($\hat{\sigma}$), covariância (COV) e correlação entre a radiação fotossinteticamente ativa e temperatura média (ρ) para as variáveis radiação fotossinteticamente ativa (PAR), temperatura média do ar (TEMP), diferença absoluta dos valores das médias dos parâmetros em relação aos valores originais (DIF), para a simulação triangular assimétrica, nas 24 datas, para os 17 locais do Estado de São Paulo. 116
- Tabela 18 – Parâmetros média (\hat{m}), desvio padrão ($\hat{\sigma}$), covariância (COV) e correlação entre a radiação fotossinteticamente ativa e temperatura média (ρ) para as variáveis radiação fotossinteticamente ativa (PAR), temperatura média do ar (TEMP), diferença absoluta dos valores das médias dos parâmetros em relação aos valores originais (DIF), para a simulação normal truncada a 1,96 desvio padrão da média, nas 24 datas, para os 17 locais do Estado de São Paulo. 117
- Tabela 19 – Parâmetros média (\hat{m}), desvio padrão ($\hat{\sigma}$), covariância (COV) e correlação entre a radiação fotossinteticamente ativa e temperatura média (ρ) para as variáveis radiação fotossinteticamente ativa (PAR), temperatura média do ar (TEMP), diferença absoluta dos valores das médias dos parâmetros em relação aos valores originais (DIF), para a simulação normal bivariada, nas 24 datas, para os 17 locais do Estado de São Paulo. 119
- Tabela 20 – Coeficiente de correlação entre os valores observados e simulados da mesma variável (ρ), índice de concordância de Willmott (ID), coeficiente angular da reta (b) e índice de desempenho de Camargo (c), para a radiação fotossinteticamente ativa (PAR) e temperatura média do ar (TEMP), para a simulação triangular assimétrica, nos 17 locais do Estado de São Paulo. 121

Tabela 21 – Coeficiente de correlação entre os valores observados e simulados da mesma variável (ρ), índice de concordância de Willmott (ID), coeficiente angular da reta (b) e índice de desempenho de Camargo (c), para a radiação fotossinteticamente ativa (PAR) e temperatura média do ar (TEMP), para a simulação normal truncada a 1,96 desvio padrão da média, nos 17 locais do Estado de São Paulo.....	122
Tabela 22 – Coeficiente de correlação entre os valores observados e simulados da mesma variável (ρ), índice de concordância de Willmott (ID), coeficiente angular da reta (b) e índice de desempenho de Camargo (c), para a radiação fotossinteticamente ativa (PAR) e temperatura média do ar (TEMP), para a simulação normal bivariada, nos 17 locais do Estado de São Paulo.	123
Tabela 23 – Número de rejeições para o teste de Bartlett, teste T e teste F, entre os valores observados e valores simulados (triangular assimétrica, normal truncada a 1,96 desvio padrão da média e normal bivariada), nos 17 locais nos 366 dias do ano (6222 testes), para a radiação fotossinteticamente ativa (PAR) e temperatura média do ar (T).....	124
Tabela 24 – Número de rejeições do teste de normalidade (Kolmogorov-Smirnov) em cada um dos 17 locais analisados no estado de São Paulo, para os 1000 valores simulados por intermédio das distribuições triangular assimétrica (TRI), normal truncada a 1,96 desvio padrão da média (NT) e normal bivariada (NBV), para radiação fotossinteticamente ativa (PAR) e temperatura média do ar (TEMP).....	127
Tabela 25 – Valor calculado da estatística do teste de Bartlett (χ^2_{Cal}) das variâncias das variáveis avaliadas para os meses do ano entre os locais do estado de São Paulo.	128
Tabela 26 – Valor calculado da estatística do teste de Bartlett (χ^2_{Cal}) das variâncias da temperatura mínima do ar média mensal de cada mês entre os locais e tamanho de amostra (número de anos) para as estações localizadas nos municípios do estado de São Paulo.	130

Tabela 27 –	Valor calculado da estatística do teste de Bartlett (χ^2_{Cat}) das variâncias da temperatura máxima do ar média mensal de cada mês entre os locais e tamanho de amostra (número de anos) para as estações localizadas nos municípios do estado de São Paulo.	131
Tabela 28 –	Valor calculado da estatística do teste de Bartlett (χ^2_{Cat}) das variâncias da temperatura média do ar média mensal de cada mês entre os locais e tamanho de amostra (número de anos) para as estações localizadas nos municípios do estado de São Paulo.	133
Tabela 29 –	Valor calculado do teste de homogeneidade de Bartlett para as variâncias entre os meses (χ^2_{Cat}) da insolação média mensal e tamanho de amostra (número de anos) nos meses do ano, máximo (Max), mínimo (Min) e média (Med) para estações localizadas nos municípios do Estado de São Paulo.	135
Tabela 30 –	Valor calculado do teste de homogeneidade de Bartlett para as variâncias entre os meses (χ^2_{Cat}) da radiação solar global média mensal e tamanho de amostra (número de anos) nos meses do ano, máximo (Max), mínimo (Min) e média (Med) para estações localizadas nos municípios do Estado de São Paulo.	136
Tabela 31 –	Valor calculado do teste de homogeneidade de Bartlett para as variâncias entre os meses (χ^2_{Cat}) da radiação fotossinteticamente ativa média mensal e tamanho de amostra (número de anos) nos meses do ano, máximo (Max), mínimo (Min) e média (Med) para estações localizadas nos municípios do Estado de São Paulo.	137
Tabela 32 –	Estações convencionais de coleta de dados, latitude (Lat, dec), longitude (Log, dec), altitude (Alt, m), ano inicial e final das variáveis avaliadas temperatura mínima (Tmin), temperatura máxima (Tmax), insolação, precipitação e fonte dos dados para o estado de São Paulo.	186

Tabela 33 – Relação das estações convencionais de coleta de dados, latitude (Lat, dec), longitude (Log, dec), altitude (Alt, m), ano inicial e final das variáveis avaliadas temperatura mínima (Tmin), temperatura máxima (Tmax), insolação, precipitação e fonte dos dados, para cidades não pertencentes ao estado de São Paulo.....	187
---	-----

1 INTRODUÇÃO

Dentre as atividades econômicas desempenhadas pelo Brasil, a agricultura representada pelo complexo agroindustrial de soja movimentava 30 bilhões de dólares, sendo que a soja tem 5% na participação no PIB brasileiro e 25% no PIB agrícola (EMBRAPA, 2005). Porém, é o setor mais atingido por oscilações climáticas. Esses eventos são os maiores responsáveis pelos desempenhos das safras agrícolas. A relação entre as variáveis climáticas e a produção agrícola é complexa, devido as primeiras exercerem influência em todo o ciclo da cultura, das mais diferentes formas.

A cultura de soja, em nível brasileiro, na safra de 2004/2005 foi cultivada em 22,4 milhões de hectares, sendo que desses, 784 mil hectares são cultivados em São Paulo. Apesar da área cultivada no Estado ser de aproximadamente 5% da área total brasileira, essa vem crescendo anualmente. Nos últimos 15 anos houve um aumento de 57% na área de soja cultivada no Estado. A média da produtividade por área de soja, em São Paulo, é inferior à média nacional, da região centro-sul e norte-nordeste, situando-se em 2.660 kg.ha⁻¹. Porém, a produção total cresceu 115% nos últimos 15 anos (CONAB, 2005). Dessa forma, a cultura apresenta grande potencialidade de aumento do rendimento, que ainda é baixos e aumento da produção total.

O cultivo da cultura de soja é amparado por resoluções Federais que prevêm indenizações por parte de eventos climáticos inesperados (granizo, tromba d'água, seca e vendaval). Cita-se a resolução nº 2403/97, que ampara as culturas de algodão, arroz, feijão, milho e soja, desde que sejam cultivadas em áreas devidamente pertencentes ao zoneamento agrícola. Além disso, somente serão considerados válidos para fins de PROAGRO, para as culturas citadas anteriormente, os produtores que optem por aplicar as recomendações técnicas referentes ao zoneamento agrícola implantado pelo Ministério da Agricultura e do Abastecimento, contemplando novo cronograma de plantio, combinado com variedades de sementes e grau de aptidão dos solos. Sendo que os municípios do estado de São Paulo são considerados habilitados na área de abrangência (BRASIL, 1997).

A extensão territorial do Brasil, assim como, do estado de São Paulo faz com que existam dificuldades no entendimento do desenvolvimento da cultura de soja em todos os ambientes. A possibilidade de execução de experimentos em todas as localidades, para testar todas as variantes de manejo e genótipos, é inexistente, devido ao custo de instalação, manejo e condução dos experimentos. Além disso, a evolução das tecnologias existentes no mercado, faz com que o

tempo necessário para tais fins (instalação, análise e difusão de tecnologia) não justifique tal procedimento.

A utilização de computadores e banco de dados torna-se uma ferramenta cada vez mais eficiente no sentido de disponibilizar informações de qualidade em um curto período a um custo muito menor em comparação a instalação de experimentos a campo. Esses podem ser realizados com a finalidade de calibrar o modelo (ajustamento mais preciso para uma determinada situação). A informática pode minimizar problemas referentes a diferentes ambientes entre os locais de produção. Dessa forma, a simulação de processos assume papel fundamental para pesquisas e gerenciamento global do cultivo de uma determinada cultura em um determinado lugar.

Novas tecnologias, como sistemas de informações geográficas, sensoriamento remoto e modelos de simulação de crescimento, desenvolvimento e produtividade de culturas, vêm sendo desenvolvidos nas últimas décadas, abrindo novos caminhos para pesquisa, planejamento e práticas agrícolas. Juntamente a essas informações, podem ser associados os elementos climáticos que são utilizados no ajuste de modelos de simulação de desenvolvimento e crescimento de culturas, tornando-se um importante instrumento para pesquisa, planejamento e monitoramento de culturas (PANDOLFO, 1995).

Como os cultivos agrícolas são extremamente dependentes das variáveis climáticas, eventos climatológicos adversos podem causar prejuízos aos cultivos. No caso da cultura de soja, quando ocorrem secas prolongadas, essas irão exercer influência na economia, na sociedade e na política da região a qual ela se manifesta (McQUIGG, 1981). Dessa forma, torna-se importante o planejamento, juntamente com a previsão de cenários futuros.

A elaboração de modelos eficientes permite a previsão de safra e a alocação correta de determinada cultura em um ambiente, estando na dependência do conhecimento das condições climáticas (radiação solar, temperatura e precipitação pluvial, principalmente), bem como da correta interpretação do levantamento de solos.

A partir da utilização de técnicas como a modelagem, é possível a criação de cenários por intermédio de simulações, que utilizam um conjunto de equações que irão representar um processo. No caso da cultura de soja, estimar-se-ão as produtividades potenciais e deplecionadas. A partir daí, pode-se traçar um conjunto de medidas que objetivam a obtenção dessas produtividades e, conseqüentemente, auxiliarem as instituições públicas e privadas para uma correta tomada de decisão.

Vantagens como economia de tempo, trabalho e quantidade de recursos, tanto de ordem financeira quanto de logística serão obtidas por intermédio do uso de modelos de culturas (PESSOA et al., 1997). Dessa forma, esse estudo auxiliará no planejamento e tomada de decisões de manejo e estratégias de gerenciamento do setor agrícola. A utilização de modelos de culturas em associação a técnicas de geoprocessamento facilitará a identificação de locais e épocas mais recomendadas para o desenvolvimento de determinada cultura, tornando-se uma importante ferramenta para o zoneamento agrícola e difusão de informações.


Os objetivos deste trabalho são: (i) caracterizar as variáveis do clima por intermédio de diferentes distribuições de probabilidade; (ii) verificar a homogeneidade espacial e temporal para as variáveis do clima; (iii) utilizar a distribuição normal bivariada para simular parâmetros utilizados na estimação de produtividade da cultura de soja; e (iv) propor um modelo para estimar a ordem de magnitude da produtividade potencial (dependente da interação temperatura e radiação fotossinteticamente ativa) e da produtividade deplecionada (dependente da interação temperatura, radiação fotossinteticamente ativa, fotoperíodo, chuva e armazenamento de água no solo) de grãos de soja, baseados nos valores diários de temperatura, insolação e chuva, para o estado de São Paulo.

2 REVISÃO BIBLIOGRÁFICA

2.1 Fisiologia da produção de soja

O conhecimento dos aspectos ligados à fisiologia da produção da cultura de soja torna-se importante para os pesquisadores que buscam de alguma forma modelar, simular ou prever resultados. As plantas de soja apresentam aspectos muito interessantes como a fotorrespiração, que devem ser levadas em consideração para realizar previsões corretas no que diz respeito a modelagem. O conhecimento das sucessivas etapas do desenvolvimento da cultura de soja (fenologia), a funcionalidade da espécie (fisiologia) e as interações com o ambiente em que se encontra (ecofisiologia), faz-se necessário para o planejamento e obtenção de elevadas produtividades.

A reação da fotossíntese pode ser representada por meio dos seus constituintes inorgânicos e elementos energéticos formados (Equação 1).



Dessa forma, são necessárias três moléculas de ATP para a fixação ou redução de cada molécula de CO_2 (LEHNINGER, 1976). Quando os produtos da fotossíntese são reduzidos por intermédio da respiração celular, são produzidos CO_2 , H_2O , energia e compostos intermediários. A partir da combinação dos substratos produzidos na respiração, existe uma reorganização e nova biossíntese de novos compostos, como os aminoácidos, proteínas, carboidratos, ácidos graxos e outros. Esses são utilizados para o crescimento estrutural, manutenção, desenvolvimento reprodutivo e armazenamento de reservas, que no final serão utilizadas dentro das diversas cadeias tróficas como fonte de alimento e fibra.

Algumas plantas, assim como a soja, fixam o CO_2 por intermédio do ciclo de Calvin, sendo que os primeiros produtos estáveis oriundos da fotossíntese são as trioses (ácido 3-fosfoglicérico ou 3PGA e glicerato), que são constituídas por três átomos de carbono. Sedyama et al. (1985) indicam que a quantidade de glicerato produzida é muito grande, onde se supõem que ela é derivada de uma hidrólise enzima-catalizada de PGA, confirmada pela rápida conversão na ausência de luz. A taxa de assimilação de CO_2 sob diversas condições por saturação por luz e temperatura ótima diferencia as plantas (DRIESSEN; KONIJN, 1992). Existe um grupo de plantas, denominadas de C3, que o primeiro elemento formado é o $\text{C}_3\text{H}_6\text{O}_3$. No outro grupo estão as plantas cujo primeiro elemento formado é o $\text{C}_4\text{H}_8\text{O}_4$. A principal diferença entre plantas C3 e

C₄ é a presença de fotorrespiração mensurável e significativa nas plantas C₃. Nessas plantas, a fotorrespiração representa 25-30% do valor da fotossíntese (MAGALHÃES, 1985). Em plantas C₄, a fotorrespiração também está presente, porém, não é mensurável pelo método de trocas gasosas com o ambiente.

O processo fotossintético ocorre no interior do cloroplasto, sendo que o CO₂ é fixado pela ribulose-1,5-bifosfato, que é um composto intermediário, também conhecido como RuBP que apresenta 5 átomos de carbono. O composto formado sofre ação da enzima ribulose-1,5-bifosfato carboxilase/oxigenase (Rubisco) e origina duas moléculas de 3-PGA. Como a Rubisco possui tanto afinidade pelo CO₂ como pelo O₂, em condições atmosféricas (0,03% de CO₂ e 21% de O₂), ambos podem ser utilizados como substrato pela enzima. O CO₂ é substituído pelo O₂ quando a concentração desse último é elevada. Como consequência desse processo, não existe a formação de 3-PGA, e sim, a síntese do fosfoglicolato (P-glicolato), que possui dois átomos de carbono. Dessa forma, a partir da oxigenação da ribulose-1,5-bifosfato, existe a formação de um 3-PGA que prossegue o ciclo de Calvin, e uma de P-glicolato, que é rapidamente metabolizada, formando CO₂ que retorna a atmosfera.

Em ambientes com baixa concentração de CO₂, ocorre uma perda considerável de energia que deveria ser utilizada para a formação de fitomassa, e segundo Booker et al. (1997), o enriquecimento de CO₂ na atmosfera causa um aumento de 56% na fotossíntese líquida, enquanto a fotorrespiração possui uma redução de 36% na principal folha apical. Além disso, elevados níveis de CO₂ promovem aumento na produtividade das plantas, devido o incremento nos fotoassimilados e supressão da fotorrespiração. A fotossíntese líquida foi aumentada e as taxas de fotorrespiração, durante o crescimento vegetativo e reprodutivo, foram reduzidos.

A fotorrespiração é um mecanismo regulador da fixação de CO₂ quando a pressão de O₂ é alta e a de CO₂ é baixa. Em plantas de ciclo C₃, existe uma concentração mínima de CO₂ que permite que ocorra fotossíntese (formação de 3-PGA), denominada de ponto de compensação de CO₂ (LARCHER, 2000). O ponto de compensação de soja é quando a concentração interna de CO₂ atinge 40ppm em ambiente a 25°C (CÂMARA; HEIFFING, 2000). A taxa de CO₂ perdida por intermédio da fotorrespiração varia conforme o ambiente e o genótipo, situando-se na faixa de 10-50% do total do carbono fixado na fotossíntese (SHIBLES et al., 1975; LEHNINGER, 1976; MÜLLER, 1981).

Com relação à pressão parcial de CO₂, essa é maior na atmosfera externa próxima a folha. Devido às sucessivas resistências de transferências, a concentração interna de CO₂ é menor do que a atmosfera que envolve a folha. A pressão de CO₂ nos espaços intercelulares é definida pelo balanço entre o consumo de CO₂ (fotossíntese) e a reposição de CO₂ (influxo do meio externo, respiração, fotorrespiração) (LARCHER, 2000). Existe uma proporcionalidade entre a pressão interna de CO₂ e a pressão externa. Essa proporcionalidade é regulada por intermédio da resistência estomática, que por sua vez, é alterada em função da intensidade fotossintética. Bauer et al. (1983) citam que a relação entre a pressão interna e a pressão externa de CO₂ é geralmente por volta de 0,7. Sob condições naturais, ou mesmo sob forte radiação, a pressão de CO₂ nos espaços intercelulares de plantas C₃ não decresce em uma proporção linear em relação à pressão parcial do CO₂ no cloroplasto. A relação entre a pressão externa da folha e a pressão interna está na ordem de 0,5 (CAEMMERER; EVANS, 1991).

A cultura de soja possui dois picos de assimilação de dióxido de carbono, esses ocorrem em R₂ (pleno florescimento) e R₅ (enchimento das vagens), onde a taxa fotossintética varia de 3,4-65,0 mg.(CO₂) dm⁻². Considerando a eficiência da interceptação de radiação solar, as plantas C₄ são mais eficientes comparadas com as C₃, porém essa diferença torna-se pequena em baixa intensidade luminosa (DRIESSEN; KONIJN, 1992). Os mesmos autores comparam a taxa de assimilação de plantas C₃ e C₄ em duas condições de temperatura. As plantas C₃ apresentam menor assimilação em qualquer um dos casos quando comparadas com as plantas C₄. Porém, sob condições climáticas mais amenas (temperaturas), a melhor taxa de acúmulo fotossintético é obtida entre 15-20°C enquanto que, sob condições mais tropicais, a melhor taxa de acúmulo varia de 25-30°C.

Atualmente, as variedades cultivadas utilizadas no Brasil, principalmente aquelas com o ciclo longo, produzem mais superfície foliar do que o necessário para a taxa fotossintética máxima. O índice de área foliar máximo é atingido entre o estágio R₄ (plena frutificação) e R₅ (início da granação), variando de 5 a 8 (CÂMARA; HEIFFING, 2000).

2.2 Latitude, longitude e elementos do clima

A produção de soja expandiu-se rapidamente em baixas latitudes (inferior a 25°), incluindo regiões próximas ao Equador. Isso ocorreu na região Centro-Oeste (cerrado) e norte do Brasil, devido à introdução de genes que conferem um longo período juvenil (SINCLAIR et al.

2005), o que causa um atraso no florescimento. Porém, somente a introdução de sensibilidade no desenvolvimento de novas variedades não tem sido suficiente para as variedades cultivadas comerciais.

Diversas condições ambientais determinam o ciclo das culturas. Segundo Pascale (1969), para que a cultura de soja prospere em determinada região, é necessário o atendimento de suas exigências térmicas, de radiação, hídricas e fotoperiódicas. O comprimento do dia, a temperatura e a chuva são os elementos do clima mais importantes para a seleção de regiões para o cultivo e a produção de soja (CÂMARA, 1991).

Para o estado de São Paulo, a cultura de soja possui potencial de expansão, sendo que a área total de cultivo é de 316.614,8 ha. Nas últimas 15 safras (1990-2005), dos 637 municípios do estado de São Paulo, 408 informam as produtividades médias obtidas em pelo menos uma safra, enquanto que os demais (229) não há informação (IBGE, 2005).

2.2.1 Temperatura e dióxido de carbono

A mudança do estágio fenológico para algumas culturas depende essencialmente da temperatura, ou seja, do acúmulo de unidades térmicas acima da temperatura mínima para o crescimento. Essa também é definida como graus-dia, que é a diferença entre a temperatura média diária e a temperatura basal exigida por uma espécie (VILLA NOVA et al., 1972). Elevadas temperaturas do ar durante o crescimento da cultura de soja reduzem o tempo para o florescimento (MAJOR et al., 1975a; MAJOR et al., 1975b; MIYASAKA; MEDINA, 1970).

Baixas temperaturas limitam severamente o crescimento das plantas em condições tropicais e subtropicais. A capacidade fotossintética é reduzida em plantas submetidas a essas condições, e essa redução é devido ao decréscimo da eficiência quântica no fotossistema II, e atividades do fotossistema I, ocorrendo uma redução dos ciclos para a formação de enzimas e ATP, no estroma das plantas C_3 (SONOIKE, 1998; ALLEN; ORT, 2001).

A temperatura do planeta aumentou de 3 a 4°C, principalmente devido a maior concentração de CO_2 na atmosfera terrestre (TAYLOR; MacCRACKEN, 1990; WATSON et al., 1990). No início do século passado, os níveis de CO_2 na atmosfera eram de 280 ppm e, atualmente chegam a 370 ppm, uma taxa de crescimento de 1,8 ppm por ano (MENDELSON; ROSENBERG, 1994; ETHERIDGE et al., 1996; KEELING; WHORF, 2000). Estima-se que no final deste século a concentração de CO_2 na atmosfera atinja de 600 a 1000 ppm (COX et al.,

2000). Diversas alterações no clima do planeta devem ocorrer, principalmente com relação à temperatura. O Plano Global da Mudança do Clima (Intergovernmental Panel on Climate Change, IPCC) estima que o incremento de temperatura seja de 1,0 a 3,5 °C em 2100, baseado nas previsões de alguns modelos de estimacão GCM, GISS, UKMO, OSU e GFDL-R30 (IPCC, 2001). Os efeitos do aumento da temperatura irão afetar a agricultura, no sentido de alterações no crescimento e desenvolvimento das plantas, sendo que em última análise, ocorrerá na produtividade e na produção de alimentos (COX et al., 2000; HANSEN et al., 2000).

A temperatura basal varia conforme a espécie vegetal, idade ou estágio fenológico da planta. Torna-se comum a adoção de uma mesma temperatura basal para uma determinada cultura durante todo o ciclo da planta, devido à facilidade de aplicação (CAMARGO, 1984). Para a cultura de soja, é considerado que a temperatura basal é de 14°C (PASCALE et al., 1963; CAMARGO, 1984). Essa cultura não tem apresentado resultados muito consistentes quando utilizado o somatório graus-dia para determinar o florescimento, devido o desenvolvimento das plantas ser influenciado pelo fotoperíodo (CAMARGO, 1984). A temperatura influencia muito o tempo, para que ocorra o florescimento em ambientes com fotoperíodo constante (baixas latitudes) (GARNER; ALLARD, 1930).

Para Pascale (1969), temperaturas médias mais elevadas causam uma redução do período pré-floração. Parker e Borthwick (1943) observaram que a indução floral foi ótima quando a temperatura nas folhas estava entre 21 e 27°C à noite, e que acima dos 27°C poucos primórdios florais foram formados. Câmara et al. (1997), estudando o desempenho de 12 cultivares de soja, submetidas a diferentes fotoperíodos (12, 13 e 14 horas) e temperaturas variáveis conforme a época de semeadura, observaram que o período compreendido entre a emergência e o início do florescimento é influenciado pelas variações de fotoperíodo e temperatura. Além disso, o fotoperíodo e a temperatura interferem na duração do período juvenil de soja, e acréscimos de fotoperíodo e de temperatura antecipam o florescimento de soja e aumentam a altura de suas plantas. Em condições de elevado fotoperíodo, em uma mesma temperatura ou mesmo fotoperíodo em elevadas temperaturas, ocasionam plantas mais elevadas.

A temperatura exerce o principal efeito determinante no crescimento, desenvolvimento e produção das plantas de soja. O incremento na respiração das plantas de soja é muito pouco influenciado pelo incremento na temperatura, apesar dos incrementos na taxa relativa de crescimento (BUNCE; ZISKA, 1996).

O crescimento e desenvolvimento da cultura de soja são otimizados quando a temperatura varia de 20 a 30°C (HOFSTRA, 1972; HESKETH et al., 1973). O incremento de área foliar em soja é devido ao enriquecimento de CO₂ e temperaturas (SIONIT et al., 1987). Na análise temporal de características individuais de crescimento, verifica-se que a elevada concentração de CO₂ é dependente da temperatura. Além disso, em temperaturas mais baixas (20-15°C), apresentaram as maiores taxas de crescimento e aumento da área foliar para elevada concentração de CO₂. A produtividade final de grãos possui uma forte influência da interação entre a concentração de CO₂ e temperatura, alterando a massa e o número de sementes por planta (HEINEMANN et al., 2005).

Siqueira et al. (1994) realizaram um estudo onde se simulou mudanças climáticas para diversas culturas, dentre elas a soja, sendo cultivadas em 13 regiões produtoras distintas, dentre elas Campinas (SP). Por intermédio da simulação de mudanças climáticas, os autores concluíram que para cultura de soja, mudanças de temperatura e precipitação não alteraram o crescimento e desenvolvimento da cultura. Em média, a produção de soja reduziu 12% abaixo de valores elevados de temperatura (6 a 8% no sul e 16% em outras regiões). A duração do ciclo foi pouco afetada, em média uma redução de 1%, sendo que as maiores influências foram obtidas na região sul do Brasil. Apesar disso, quando se considerou o incremento de CO₂ na atmosfera, verificou-se que por intermédio do modelo de crescimento SOYGRO houve aumentos significativos na produção de grãos. A produtividade média aumentou por volta de 22% em todas as regiões, exceto no nordeste, onde houve uma redução de 15%. Esses autores afirmam que o aumento de CO₂ na atmosfera, apesar de aumentar a temperatura, aumentará a produtividade média brasileira. Especificamente para a região centro-sul (SP), o aumento varia de 22-32% na produção de grãos para condições de sequeiro, e de até 30% para regiões com irrigação suplementar. além de políticas agrícolas e manejo da cultura.

2.2.2 Fotoperíodo

Fotoperíodo é definido como o tempo, durante as 24 horas do dia, em que o sol brilha (OMETTO, 1981). Além disso, o fotoperíodo também pode ser definido como o tempo em horas entre o nascer e o pôr do sol (GOUDRIAAN; van LAAR, 1994). O fotoperíodo, em um determinado lugar é determinado pela latitude local, sendo a principal variável associada à influência da data de semeadura sobre a maturação. Contudo, outras variáveis, como a

acumulação térmica e a umidade do solo, podem apresentar efeitos importantes (PASCALE et al., 1963). Além das condições ambientais, foram identificados 7 lóculos (*E1* a *E7*), que condicionam o tempo para o florescimento, maturação e a sensibilidade ao fotoperíodo (STEWART et al., 2003). Exceto o lóculo *E6*, encontrado em germoplasmas tropicais, em todos os outros seis lóculos a dominância total ou dominância parcial resulta em maior sensibilidade fotoperiódica e atraso no florescimento, sendo os alelos recessivos (COBER et al., 2001). A dominância de cada um dos alelos, em cada um dos lóculos, exerce efeitos de diferentes magnitudes, sendo o *E1* o mais responsivo, diferenciando do grupo formado pelos outros alelos (STEWART et al., 2003). Dessa forma, se forem descobertas informações referentes às funções de cada um dos alelos, será possível definir qual a melhor época para a semeadura em cada região. A soja é considerada como planta de dia curto, sendo que o fotoperíodo afeta as taxas de emergência até a indução floral, em particular o tempo necessário para o florescimento, ou seja, em condições de fotoperíodos longos ocorre o atraso para o florescimento e maturação dos grãos (MAJOR, 1980).

Os efeitos do fotoperíodo sobre o florescimento de soja têm sido estudados desde o início do século XX (GARNER; ALLARD, 1920; GARNER; ALLARD 1923). O fotoperíodo possui o principal papel na indução do florescimento (BORTHWICK; PARKER, 1938), na diferenciação dos órgãos florais (ZHANG et al., 2001), na microsporogênese (NIELSON, 1942) no desenvolvimento após o florescimento (JOHNSON et al., 1960; FISHER, 1963; THOMAS; RAPER, 1976; RAPER; THOMAS, 1978; GUIAMET; NAKAYAMA, 1984; MORANDI et al., 1988; HAN; WANG, 1995; KANTOLIC; SLAFER, 2001) e formação dos grãos (MANN; JAWORSKI, 1970; RAPER; THOMAS, 1978; KANTOLIC; SLAFER, 2001) das plantas de soja.

Cada cultivar de soja exige um mínimo crítico de ausência de luz para que seja induzida ao florescimento. Onde, se uma determinada variedade cultivada estiver submetidas durante muito tempo sob condições de dias longos, o período vegetativo poderá permanecer quase que indefinidamente. A indução para o florescimento depende de características genéticas da variedade cultivada e do local onde ela será cultivada, podendo variar entre cultivares de soja (JOHNSON et al., 1960). Objetivando entender os mecanismos genéticos relacionados com o tempo para o florescimento em soja, Bonato e Vello (1999) verificaram que o retardamento do início do florescimento é determinado por alelos recessivos, sendo que os alelos que condicionam

a precocidade exibiram dominância parcial. As informações genéticas apresentadas, sobre o tempo para o florescimento quando avaliadas em conjunto com os resultados obtidos por outros pesquisadores, indicam que o tipo de herança depende mais dos genótipos considerados que de uma faixa fotoperiódica específica.

O tempo requerido para a indução floral dependerá do comprimento do dia, onde esse irá ocorrer de forma mais rápida em locais com dias curtos, comparados a locais com dias longos. Uma consequência da indução floral antecipada é a precoce diferenciação de talos e folhas em órgãos reprodutivos, determinando o tamanho final da planta, e conseqüentemente, o seu potencial produtivo. Cultivares de maturação tardia são, geralmente, mais sensíveis ao fotoperíodo do que cultivares precoces (LAWN; BYTH, 1973; MAJOR et al., 1975b).

Rodrigues et al. (2001) estudaram o efeito do fotoperíodo e da temperatura na duração do período de florescimento, e avaliaram a resposta de um modelo linear simples para prever o período de floração de genótipos de soja de diferentes grupos de maturação, semeados em épocas diferentes. Esses autores verificaram que o fotoperíodo crítico varia de acordo com a temperatura, tornando-se maior com o aumento dela. Nos genótipos em estudo, o fotoperíodo crítico foi estimado a partir do modelo estudado, e aumentou numa taxa de 16 minutos $^{\circ}\text{C}^{-1}$ na variedade cultivada Ocepar 14. Da mesma forma, a temperatura basal variou com o fotoperíodo, numa taxa de 3,4 $^{\circ}\text{C}\cdot\text{h}^{-1}$ de aumento no fotoperíodo, no mesmo genótipo. Temperaturas inferiores aumentaram o número de dias para o florescimento. Porém, com a elevação das temperaturas, o número de dias para o florescimento reduziu-se para os quatro fotoperíodos testados (11, 12, 13 e 14 horas), além de haver uma variação pequena nas datas de floração, contrastando com temperaturas mais baixas.

A taxa de desenvolvimento de duas variedades de soja (BR-27 e BR-15) até o florescimento foi reduzida devido ao aumento do fotoperíodo de 11,5 até 14,2 horas (SINCLAIR et al., 2005). Nesse caso, a variedade BR-15 apresentou uma redução muito mais drástica em comparação com a cultivar BR-27. Sendo assim, o fotoperíodo é decisivo na duração do ciclo da planta e as variedades apresentam desempenhos distintos quando submetidos ao mesmo fotoperíodo. Além disso, esse fator exerce influência em todos os estádios fenológicos da planta de soja, bem como na diferenciação dos seus órgãos constituintes.

2.2.3 Radiação solar

O aumento da produção de alimentos relaciona-se diretamente com a maximização da utilização dos recursos naturais. Dentre esse, a radiação solar constitui-se uma fonte energética básica. Monteith (1994) indica que a produção de matéria seca pode ser expressa das seguintes formas: (i) recurso disponível por unidade de solo; (ii) quantidade de recurso capturado por unidade de recurso disponível (eficiência de captura) e (iii) taxa de matéria seca por unidade de recurso capturado (eficiência de captura). Além disso, se a disponibilidade de nutrientes e água para as plantas não for limitante, a radiação solar disponível para o processo fotossintético irá determinar a produção de fitomassa. Segundo Taiz e Zieger (2004), a radiação solar é um dos fatores que mais limitam o crescimento e desenvolvimento das plantas. A radiação solar origina toda a energia necessária para a transformação do CO₂ atmosférico em energia metabólica.

A radiação solar que chega até a superfície terrestre pode ser separada em duas fases, uma quando a radiação é direta e a outra é chamada de difusa, que é refletida ou espalhada por nuvens e pela atmosfera (GOUDRIAAN; van LAAR, 1994). Cada uma dessas fases pode ser dividida mais duas vezes, que são chamadas de bandas, a primeira é a de baixo comprimento de onda (inferior a 3000 nm) e a segunda é a radiação térmica (superior a 3000 nm). Quando se analisa em separado a radiação de baixo comprimento de onda, separa-se esta também em bandas que possuem diferentes efeitos sobre as plantas. A faixa da radiação visível varia de 400 a 700 nm, e são especialmente estudadas na área agrônômica, devido ser radiação fotossinteticamente ativa (KUBINS, 1971).

Os fluxos de radiação em direção a superfície terrestre compõem-se da radiação solar incidente de ondas curtas (direta e difusa) e da radiação de ondas longas. Em contrapartida, a superfície reflete ondas curtas e radiação de ondas longas emitidas pela superfície para a atmosfera (TANNER; LEMON, 1962). A intensidade com que as ondas curtas são refletidas para o espaço (albedo) varia com o ângulo de incidência solar, grau de cobertura do solo, umidade do solo e das plantas e tipo e quantidade de cobertura por nuvens (BLAD; BAKER, 1972). A partir das trocas verticais de radiação é possível definir o saldo de radiação, que será utilizado nos processos de evaporação, e transpiração das plantas nos processos de aquecimento do ar, do solo e das plantas, e no processo de fotossíntese.

A radiação solar atua diretamente no processo fotossintético, na alongação da haste principal e formação de ramificações, expansão foliar, manutenção de vagens e grãos e fixação

biológica de nitrogênio (CÂMARA, 2000). Somente a presença de radiação solar não é suficiente para a produção de fitomassa seca. A produção de fitomassa depende da radiação fotossinteticamente ativa (RFA) e interceptada e a eficiência de utilização dessa energia pelo processo fotossintético (SHIBLES; WEBER, 1965). A produção de grãos de soja não é apenas função direta da radiação solar, mas também da partição dos fotoassimilados que são destinados para a sua produção. Durante a fase de enchimento de grãos, a interceptação de radiação fotossinteticamente ativa deve ser máxima, com isso haverá uma maximização da taxa fotossintética e uma maior produção de fotoassimilados e, conseqüentemente, uma maior produção de grãos (SHIBLES; WEBER, 1966).

Altas intensidades luminosas absorvidas pela planta podem ocasionar a fotoinibição, resultando, assim, na saturação luminosa (JIANG et al., 2006; ADAMS; ADAMS, 1992). Dessa forma, a cultura de soja é classificada como C₃, o que proporciona uma baixa capacidade competitiva, sendo que durante parte do seu ciclo, a planta de soja está sujeita ao estresse hídrico. Sendo assim, os seus mecanismos de captura e de utilização dos recursos nos diferentes estádios de desenvolvimento podem ser afetados (MUCHOW et al., 1993).

Por fim, quando considera-se a relação entre a fotossíntese e a intensidade de luz para plantas C₃ e C₄, verifica-se que nas plantas C₃ existe uma saturação com aproximadamente 1/3 da luz solar máxima, e nas plantas C₄ não se atinge a saturação com aumento da intensidade luminosa (MAGALHÃES, 1985).

2.2.4 Condições hídricas

Mesmo com todo o progresso que a pesquisa tem alcançado por intermédio do desenvolvimento de genótipos mais adaptados e melhorias no manejo, o desenvolvimento e produtividade da cultura de soja podem ser limitados por estresses hídricos durante os estádios mais críticos do seu ciclo (MAEHLER et al., 2003). As regiões com precipitações médias anuais de 700 a 1.000 mm, e durante o ciclo de cultivo da cultura, as precipitações variando de 500 a 700 mm, são consideradas regiões aptas para o cultivo de soja (CÂMARA; HEIFFING, 2000). Os períodos mais críticos à deficiência hídrica são determinados por intermédio de estudos que submetem diferentes níveis de irrigação em diferentes estádios fenológicos. A maioria dos resultados indica que a sensibilidade da cultura é mínima durante a fase vegetativa, a não ser que a severidade limite muito o porte da planta (BOERMA; ASHLEY, 1982), e máxima durante o

período reprodutivo, principalmente na formação de legumes e enchimento de grãos (KORTE et al., 1983). Segundo COOPER (2003), a água é o fator inicial limitante que limita a produtividade máxima da cultura de soja.

Quando o solo fornece uma boa disponibilidade hídrica e a demanda evaporativa da atmosfera é elevada, a taxa de transpiração também é elevada. Porém, a absorção de água pelas raízes da planta não é suficiente, devido às perdas por transpiração. Isso é devido a um desequilíbrio entre a absorção e a transpiração. Essa condição irá ocasionar uma redução no potencial hídrico (mais negativo), o que levará a um estresse hídrico se a intensidade desse processo for elevada.

Alguns autores, como QUEIROZ et al. (1996), indicam que fatores como a intensidade, duração, época de ocorrência e interação com outros fatores determinantes da expressão da produtividade final, determinam os efeitos da deficiência hídrica. Ao ocorrer deficiência hídrica durante a formação de flores, possuem o período de florescimento reduzido e produzem um menor número de flores e legumes pelo abortamento de flores (SIONIT; KRAMER, 1977). Os mesmos autores destacam que com a deficiência hídrica no período de enchimento de grãos, reduz o tamanho e a massa dos grãos, devido a redução de fotoassimilados pela planta ou pela inibição do metabolismo dos grãos (SALINAS et al., 1996). Com a irrigação, o número de legumes fixados na planta é maior, porém o número de grãos por legume é pouco alterado em cultivares com hábito de crescimento determinado, pois essa característica é intrínseca ao genótipo e pouco influenciada pelo ambiente (THOMAS; COSTA, 1994). Quanto às características nos grãos, pode ser alterada a massa dos grãos (THOMAS; COSTA, 1994), porém, a taxa de enchimento é pouco alterada pela disponibilidade hídrica da planta (WESTGATE et al., 1989). Essas alterações são resultados diretos da redução da área foliar, diminuição da fotossíntese e alterações em vários outros processos, além de alterar o ambiente físico da cultura, por modificar o balanço de energia do sistema (BERGAMASCHI, 1992).

Com o objetivo de determinar o efeito da disponibilidade hídrica e arranjo de plantas no período reprodutivo e seus componentes, durante a ontogenia de duas variedades de soja, Maehler et al. (2003) concluíram que a irrigação proporciona incremento na produtividade potencial de grãos, pela redução do aborto de flores e abscisão de legumes, aumento na massa dos grãos e número de grãos por legume.

Berlato (1987) realizou um estudo relacionando a produtividade de grãos de soja com o consumo relativo de água para diversas localidades do Rio Grande do Sul. Concluiu que o consumo relativo de água explicou 89, 86 e 85% da variação da produtividade de grãos de soja dos grupos de maturação precoce, médio e tardio, respectivamente, durante o período crítico da cultura (do início da floração até o início do enchimento de grãos R1-R5). Matzenauer (2002) definiu três índices de risco para a produção de soja no Rio Grande do Sul, que podem ser associados às áreas de produção: áreas de baixo risco (o consumo relativo de água, índice E_{Tr}/E_{Tc} , não é maior que 0,60), áreas de risco médio (o consumo relativo de água é igual ou inferior a 0,60 e igual ou superior a 0,40) e áreas de alto risco (áreas onde o consumo relativo de água é inferior a 0,40).

Pode-se realizar estimativas das produtividades de grãos por intermédio da utilização da modelagem, que irá relacionar o índice E_{Tr}/E_{Tc} (Evapotranspiração real e evapotranspiração da cultura, respectivamente), que possui a vantagem de estimar a produtividade de grão com até 30 dias antes da maturação da cultura, possibilitando, assim, um melhor planejamento.

Berlato e Bergamaschi (1979), determinando o consumo estacional de água pela cultura de soja no Rio Grande do Sul, obtiveram um consumo médio diário de 5,8 mm para a variedade Bragg. Esse consumo, expresso pela evapotranspiração diária, variou desde 2,2 mm no período entre a semeadura e a emergência, até o valor máximo de 7,4 mm, atingido no período compreendido entre o início do florescimento e o máximo surgimento de vagens. Os mesmos autores obtiveram valores máximos da relação E_{Tr}/E_{Tp} entre a evapotranspiração real e a evaporação potencial (estimada utilizando o tanque de evaporação classe A).

Para o estado de São Paulo, as exigências hídricas foram estudadas por Arruda et al. (1978). Esses autores verificaram que a condição hídrica possui importância no estágio do estabelecimento da cultura, reduzindo-se na época de crescimento vegetativo e aumentando gradativamente a partir do florescimento até a formação de vagens. As grandes quantidades de água exigidas pela cultura de soja, cerca de 580 litros, devem ser transpiradas para que por intermédio da fotossíntese seja produzido 1 kg de fitomassa, sendo característica de plantas C_3 (SHIBLES et al., 1975).

2.3 Produtividade da cultura de soja

Para definirmos se uma determinada produtividade de soja está condizente com a potencialidade da cultura, em um dado ambiente, deve-se primeiro definir o nível de estimação que está sendo enfocado (produtividade genética, potencial, deplecionada ou altas produtividades a campo). Com base nos elementos do clima (radiação solar, concentração de CO₂ e disponibilidade hídrica), vários autores (LOOMIS; WILLIAMS, 1963; DOORENBOS; KASSAM, 1979) sugerem métodos para estimar a produtividade máxima em diferentes culturas.

Em produções comerciais, as produtividades para a cultura de soja ultrapassaram 4.000 kg.ha⁻¹, mas nem todos os produtores conseguem atingir tais níveis, devido às limitações dos recursos naturais que regulam tais produtividades. Podem-se agrupar esses recursos naturais em três categorias, a saber: clima, manejo (nutrientes, solo, pragas, doenças e plantas daninhas) e potencial genético da cultura. Contudo, serão destacados a seguir os principais pontos que diferenciam os níveis de potencial produtivo.

2.3.1 Potencial genético

Atualmente, estudiosos estão sugerindo que o potencial produtivo das culturas está sendo atingido, e que aumentos nos rendimentos logo cessarão. As estimativas para o desempenho das produções de cereais não são unânimes. Estimativas do Banco Mundial e da FAO, baseadas em tendências de crescimento que se tem mantido praticamente constante desde 1950, apontam para um crescimento da produção mundial de grãos (COELHO et al., 2003). Por outro lado, o Ministério da Agricultura do Japão indica que as condições da agricultura mudaram muito durante os últimos anos, e que as produtividades que aumentaram linearmente entre 1960 e 1990, não deverão continuar aumentando no futuro.

A produtividade, considerando a sua capacidade genética, é elevado, porém ela não é atingida, devido à abscisão dos órgãos reprodutivos (flores, legumes e sementes). Isso ocorre devido à interação da planta com o ambiente, que compete por recursos do meio (NAVARO JÚNIOR; COSTA, 2002). A definição do elevado potencial produtivo pelas plantas de soja é em função da grande produção de flores, mesmo após o período de enchimento de grãos, porém, nem todas as flores produzem grãos, e com isso, o potencial produtivo é reduzido (DYBING, 1994).

O potencial genético é exteriorizado, na sua totalidade, quando os fatores bióticos e abióticos não interferem na expressão da sua capacidade de produção. No manejo das lavouras de

soja, geralmente é enfatizado o período do enchimento do grão quando esse é determinado (DYBING, 1994). Porém, para que haja grãos, devem-se analisar aspectos relacionados à sua formação, como por exemplo, a produção e fixação de flores e legumes, pois o seu mecanismo não possui um entendimento completo (McBLAIN; HUME, 1981). O rendimento final de cada uma das plantas de soja depende da quantidade de flores que são emitidas, do número de flores que são fertilizadas e transformam-se em legumes e, posteriormente, o número de legumes que originam grãos (JIANG; EGLI, 1993; PIRES et al., 2000). Porém, com a adversidade ambiental, muitas das flores caem antes de serem fertilizadas, outras logo após e outras poucas são abortadas quando já se apresentam em forma de legume. A condição de maior abscisão de flores, em relação aos legumes, é devido uma proteção que a própria planta possui, evitando assim gasto energético desnecessário.

As estruturas reprodutivas se desenvolvem basicamente em dois locais, próximo a inserção do nó e na posição distal do racemo. As primeiras flores são as surgidas na primeira posição, e se desenvolvem primeiro e estabelecem mais cedo o tamanho da demanda superior em relação às demais estruturas formadas, que irão possuir uma maior propensão em sofrer abscisão (SPOLLEN et al., 1986; WIEBOLD, 1990).

Por intermédio da seleção de genótipos com baixo nível de abscisão, verificou-se que houve uma elevação na produtividade de soja (SHARMA et al., 1990). Além disso, dentre os componentes de produção de soja, os mais importantes são o número de legumes por planta e de grãos por legume, sendo que ao contrário do que se pensa, a compensação obtida no tamanho dos grãos é apenas parcial quando o número de grãos é reduzido (HERBERT; LITCHFIELD, 1982).

O início do processo de abscisão ocorre, possivelmente, entre as estruturas reprodutivas no racemo, devido à competição pelos fotoassimilados disponíveis. Autores como Spollen et al. (1986) e Wiebold (1990), sugerem que o controle de abortos de estruturas reprodutivas atua na região do nó. Dessa forma, o suprimento de assimilados é fator importante nesse processo (WIEBOLD; PANCIERA, 1990).

O melhoramento da cultura de soja atua no sentido de selecionar apenas três óvulos por legume, o que inflaciona a importância do número de legumes por planta. Então, a formação e fixação dos legumes são de extrema importância. Além disso, mesmo que os legumes formados mais tarde possuam um número menor de óvulos e grãos, o abortamento também poderá ocorrer (McBLAIN; HUME, 1981). Nessa concepção, a seleção de um menor número de flores por nó é

mais fácil que reduzir a percentagem de queda das flores. Isso ocorre em razão da herdabilidade da característica. Então para a obtenção de elevados rendimentos seria mais conveniente a seleção de um número adequado de flores por racemos ao invés de uma alta produção de flores, devido ao desperdício de energia na planta (SHARMA et al., 1990).

Com o objetivo de quantificar a expressão do potencial genético de produtividade de seis genótipos de soja de diferentes ciclos durante a ontogenia, Navarro Júnior e Costa (2002), conduziram um experimento em Eldorado do Sul (RS). Como conclusões, esses autores indicam que a produção moderada de flores e de estruturas reprodutivas por nó fértil, juntamente com a produção de legumes com dois ou com três grãos, é responsável pela expressão de alto potencial de produtividade de grãos em dois dos genótipos testados (FR-2003 e RS 9-Itaúba). Além disso, genótipos com alto potencial produtivo de grãos em R8, não apresentam os maiores potenciais de rendimento de grãos em R2 e R5; porém, são os que apresentam as menores diferenças entre o potencial estimado em R5 e R2. Ainda, esses autores concordam com Sharma et al. (1990) a respeito da característica da alta produção de flores não ser adequada para a seleção de plantas com maior potencial de produção de grãos, uma vez que esse fato não se traduz em maior produção final de grãos por planta.

O potencial de produtividade pode ser estimado durante a ontogenia, de modo a levar-se em consideração a quantificação das estruturas reprodutivas (flores e legumes) da cultura, possibilitando verificar o efeito de diferentes práticas sobre a produção e fixação dessas estruturas. Em estudos realizados por Ventimiglia et al. (1999), verifica-se que a produtividade potencial em R2 (florescimento) chegaria a 18.000 kg.ha⁻¹ se todas as flores dessem origem a legumes e esses originassem grãos. Porém, se todos os legumes formados até R5 (enchimento de grãos) alcançassem à maturação, a produtividade seria de 10.000 kg.ha⁻¹, mas a produtividade alcançada em R8 foi de 4.600 kg.ha⁻¹. A produção de óvulos durante a ontogenia é afetada por variações nas populações e nas densidades de plantas de soja (PIRES et al., 2000). A produtividade potencial está excluindo as exigências hídricas da cultura.

2.3.2 Produtividade potencial

A produtividade é função dos componentes formadores e das características do local, bem como as suas qualidades nos sistemas de uso da terra. Os modelos de estimação de uso da terra não são simples. Eles são descritos como dinâmicos no que diz respeito aos seus requerimentos e

aos quais correspondem as qualidades dos locais. Devem-se considerar ainda, as suas interações diretas e indiretas, entre os seus componentes constituintes.

Quando o objetivo é observar a produtividade potencial de uma determinada espécie, primeiramente devem-se entender as inter-relações entre o genótipo, o ambiente e o manejo. Quanto maior for o conhecimento do genótipo, melhor será a utilização desse para potencializar o seu uso. O ambiente de produção também deve ser conhecido quanto as suas potencialidades, para melhorar os aspectos deficitários e maximizar a utilização das características favoráveis. Os elementos que constituem o meio são os bióticos e abióticos, que podem ser favoráveis ou desfavoráveis à produção. Dentre os bióticos estão as pragas, doenças, plantas daninhas e microrganismos fixadores de nitrogênio. No caso dos abióticos, têm-se os elementos do clima e do solo, que irão interferir de diferentes formas, conforme a sua intensidade de presença. Dessa forma, o ambiente deve favorecer ao máximo o desenvolvimento e a produção da espécie escolhida para o cultivo. E por último, deve-se destacar o homem e a sua capacidade de modificação do meio. A gerência e a modificação do ambiente, ou sistema, devem-se a sensibilidade de percepção que o homem possui sobre as interações existentes entre o ambiente e a planta. Os fatores limitantes da produtividade devem ser rapidamente superados para que o potencial produtivo da cultura seja explorado ao máximo.

Os sistemas de simulação de produção devem definir a cultura a ser utilizada em determinada região, além do manejo aplicado. Segundo Driessen e Konijn (1992), modelos de simulação de produção são compostos por inúmeros outros modelos, cada etapa determina os requerimentos utilizadas em cada região, além da qualidade da região, para assim estimar a produção potencial. Primeiramente, será quantificada a performance da cultura, onde será levada em consideração somente a temperatura e a radiação solar. As demais características do local, onde será estimada a produção potencial, serão consideradas em nível máximo para o desenvolvimento da cultura.

Define-se produtividade potencial de grãos como a produção de uma variedade cultivada em ambiente ao qual está adaptada, sem limitações edafoclimáticas e nutricionais, livre da ação de pragas e doenças, e com os demais estresses efetivamente controlados (EVANS, 1993). Ou seja, é a produtividade máxima de uma cultura quando todos os outros fatores limitantes, passíveis de controles, são removidos ou minimizados, independente da viabilidade econômica do sistema. Segundo COOPER (2003), os objetivos de estudar as produtividades máximas são: (i)

tentar repetir nos campos de multiplicação as produtividades encontradas nas parcelas experimentais; (ii) detectar os fatores limitantes da produção de soja e (iii) identificar as produtividades máximas possíveis para soja.

A orientação de processos de modelos de crescimento de plantas tem sido usada extensivamente em estudos de impactos climáticos (ALEXANDROV; HOOGENBOON, 2000; GUEREÑA et al., 2001), devido a mudanças climáticas alterarem a simulação do crescimento de plantas.

2.3.3 Produtividade deplecionada

A produtividade deplecionada de grãos, ou ainda, estimativa da produção de grãos, leva em consideração questões relacionadas com a disponibilidade hídrica e/ou o suprimento de nutrientes, que muitas vezes causa estresse nas plantas de soja e reduz a produtividade total. O crescimento da planta depende da taxa fotossintética por unidade de área da folha, área total disponível para a fotossíntese e duração da área foliar (BEEG; TURNER, 1976). Em contrapartida, a senescência foliar das folhas mais velhas pode ser acelerada para reduzir o consumo de água pela planta. Esse aspecto deve ser considerado ao modelarmos a produção da cultura de soja, sendo que esse é um fator de redução da produtividade potencial.

Analisando os estádios de desenvolvimento e crescimento que são mais afetados pelo estresse hídrico, considera-se que o período entre a semeadura e a emergência e entre a floração e o enchimento de grãos (desenvolvimento de vagens), são os períodos mais críticos. Sendo que no primeiro, pode ocorrer o atraso no crescimento das plantas, e no segundo a queda de flores e vagens (DOORENBOS; KASSAM, 1979).

As relações entre a redução da produtividade e as condições hídricas podem ser descritas por intermédio de três hipóteses, segundo Vossen (1990): (i) a redução da produtividade é relacionada com o deficiência hídrica acumulado durante todo o ciclo da cultura; (ii) a deficiência hídrica afeta diretamente a produtividade, dependendo do estágio fenológico, sendo o efeito final aditivo e (iii) a deficiência hídrica afeta diretamente a produção, dependendo do estágio fenológico que ocorre o estresse hídrico, sendo o efeito final multiplicativo.

Com o propósito de estabelecer um modelo de penalização independente da cultura, Segovia e Andrade (1982) utilizaram a relação de que, quando o teor de água do solo se torna menor que a umidade ideal, a produtividade dever ser reduzida. Assim, esses autores

estabeleceram as variações de produtividade de uma cultura em função da precipitação pluvial e porcentagem de espaço poroso no solo. A partir desse modelo, obteve-se a relação E_{Tr}/E_{Tp} (evapotranspiração real e potencial) e teores de água disponíveis, baseados no trabalho de Mason e Smith (1980) para a penalização da cultura de soja em decorrência do déficit hídrico. Além disso, introduziu-se um fator de correção para excedentes hídricos, denominado de fator de excedente, diferenciando-se assim, do modelo original de Segovia e Andrade (1982), os efeitos de déficit e do excedente hídrico.

Um dos modelos de crescimento de planta é o CROPGRO-Soybean v.35, que é um processo orientado de modelagem que simula carbono, água e balanço de nitrogênio para a cultura de soja, em nível de planta e de solo (HOOGENBOOM et al., 1994; BOOTE et al., 1998). As equações do modelo expressam as relações entre os processos ocorridos nas plantas (incluindo o desenvolvimento fenológico, fotossíntese, respiração, acúmulo de biomassa, partição de fotoassimilados e o balanço de água e entre o solo e a planta) com a temperatura, o fotoperíodo, insolação e estresse por água e nitrogênio.

Carbone et al. (2003) utilizaram o modelo CROPGRO-Soybean v.35 para a cultura de soja, e fizeram o comparativo entre a produtividade simulada e observada em oito estações de pesquisa, para três grupos de maturação (V, VI, VII). Esses dados foram analisados para diferentes anos, variando de 6 até 21, dependendo da localidade. O grupo V foi avaliado em cinco localidades diferentes, sendo que em todos a média das produtividades observadas ($1,83 \text{ t.ha}^{-1}$) foi sempre inferior à média simulada ($2,22 \text{ t.ha}^{-1}$). O grupo de maturação VI foi testado em quatro diferentes locais, sendo que as médias das quatro localidades, em todos os anos testados as produtividades simuladas ($1,99 \text{ t.ha}^{-1}$) foram superiores às observadas ($1,88 \text{ t.ha}^{-1}$). No grupo de maturação VII, que avaliou a produtividade de soja em oito locais, os resultados concordam com os outros dois grupos de maturação, sendo que as produtividades estimadas foram de $2,29 \text{ t.ha}^{-1}$, e as observadas foram de $2,02 \text{ t.ha}^{-1}$. Essa diferença entre as produtividades estimadas e observadas é devido ao modelo CROPGRO-Soybean, não levar em consideração a interferência de plantas daninhas, doenças, pragas e interferência por vento (BATCHELOR et al., 1993). Além disso, Carbone et al. (2003) observam que o coeficiente de variação entre os valores observados e os estimados foram bastante próximos. O coeficiente de determinação e o índice de concordância de Willmont apresentaram valores acima de 0,7 em média.

2.3.4 Altas produtividades

Em algumas condições especiais, é possível obter-se produções por área bem elevadas, chegando até $8.000 \text{ kg}\cdot\text{ha}^{-1}$. Para que essas produtividades possam ser atingidas, deve-se maximizar os recursos do meio, utilizando o genótipo mais adaptado para um determinado local. A seguir, serão apresentados alguns dos recordes de produção de soja dos últimos 30 anos, em várias localidades do mundo.

Segundo Cooper (2003), o primeiro concurso nacional de produtividade de soja nos Estados Unidos ocorreu em 1966, e registrou o recorde de produtividade de $4.000 \text{ kg}\cdot\text{ha}^{-1}$, e as produtividades em parcelas experimentais variaram de 3.000 a $4.000 \text{ kg}\cdot\text{ha}^{-1}$. Esses resultados foram obtidos na Universidade de Minnesota. Logo após foram registrados $6.000 \text{ kg}\cdot\text{ha}^{-1}$ (1967) por quatro agricultores. E no ano seguinte superou-se $6.700 \text{ kg}\cdot\text{ha}^{-1}$. Nesse período, as plantas de soja eram altas, com aproximadamente 150 cm em R_2 , e elevadas produtividades eram alcançadas quando algum evento climático não ocasionava o acamamento das plantas.

Algumas elevadas produtividades são destacadas por Cooper (2003) para três regiões dos Estados Unidos. De 1980 a 1983, os recordes de produtividade variaram de $6.203 \text{ kg}\cdot\text{ha}^{-1}$ até $7.911 \text{ kg}\cdot\text{ha}^{-1}$. Nos anos de 1982 a 1999 os recordes variaram de $6.050 \text{ kg}\cdot\text{ha}^{-1}$ até $6.817 \text{ kg}\cdot\text{ha}^{-1}$. Na Austrália em 1984 verificaram-se produtividades variando de 8.004 a $8.604 \text{ kg}\cdot\text{ha}^{-1}$. No estado de São Paulo o recorde de produção para a cultura de soja foi na cidade de Andradina, que no ano de 2001 produziu $5.400 \text{ kg}\cdot\text{ha}^{-1}$ em média (IBGE, 2005).

2.4 Modelagem em agricultura

Os pesquisadores da área agrônômica desenvolvem seus estudos nas mais diversas áreas do conhecimento, onde a quantidade de informações sobre os mais diversos temas ainda são passíveis de serem ampliadas. Considerando que a natureza é um sistema complexo, o melhor entendimento é dado quando subdividimos. Os níveis de organização podem ser assim divididos: planeta, ecossistema, cultura, planta, órgão, tecido, célula, molécula, átomo e partícula subatômica. Dentro de cada um desses níveis organizacionais, diversos pesquisadores desenvolvem os seus estudos e acumulam conhecimento, definindo assim, a melhor maneira de obter resultados que auxiliem nas produções das culturas agrícolas, no meio ambiente e na saúde humana.

Para que os resultados das pesquisas sejam confiáveis, existe a necessidade da realização de experimentos agrícolas que, cada vez mais, possuem um elevado custo de instalação, manutenção e obtenção dos dados. Além disso, o tempo que é utilizado para a condução de experimentos nem sempre é disponível. Em outros casos, não existe possibilidade de instalação de experimentos pela complexidade do problema exigindo-se que a tomada decisória seja rápida. Para contornar as situações apresentadas anteriormente, pode-se propor a descrição de um sistema real que o represente na escala do objetivo do estudo. Para que esta simplificação seja possível exige-se que exista um elevado conhecimento dos conceitos básicos de funcionamento do sistema. Assim, é possível a elaboração de modelos matemáticos que representem o problema de forma mais eficiente e, posteriormente, haja uma transcrição para a linguagem computacional, viabilizando o acompanhamento da dinâmica desse sistema pela simulação de cenários alternativos, muitos deles ainda não testados em sistemas reais (PESSOA et al., 1997).

A utilização das técnicas de modelagem pode ser realizada para as mais diversas áreas, como na gerência de indústrias, pela melhor formação de estoques, na comercialização, em políticas de administração de recursos, políticas agrícolas e de zoneamento, em áreas da saúde, esportes, definições das linhas de pesquisa e na agricultura. A partir dos elementos do clima, como temperatura do ciclo de produção, precipitação e radiação solar, e elementos do ambiente como a quantidade de fertilizantes utilizados e tipo de solo, podem-se estimar a produção para um determinado local. A utilização de modelos é realizada há mais de 270 anos, com o objetivo de quantificar os efeitos das variáveis ambientais no crescimento e no desenvolvimento das culturas. Evidente é que tal afirmação é baseada no fato de que Réaumur, em 1735, fez a associação entre temperatura (graus-dia) e o desenvolvimento de culturas. Ele estava propondo um dos modelos empíricos mais eficientes que se conhece em agrometeorologia (COSTA, 1997).

2.4.1 Modelos e modelagem

As análises de sistemas organizam atributos de interesse particular, que tem por objetivo conceituar, integrar e generalizar o conhecimento específico por intermédio da simplificação da realidade (mais complexa), que resulta em uma ferramenta de auxílio para simulações de diversos cenários, que é a confecção de modelos.

A palavra modelo é derivada de “modus” e representa uma medida, implicando em uma mudança de escala e suas determinações. Conceitualmente, são as representações idealizadas para

situações do mundo real (CAIXETA FILHO, 2001), ou ainda, equações ou conjunto delas, podendo representar quantitativamente as suposições e hipóteses idealizadas sobre o sistema real (THORNLEY, 1976). Considera-se modelagem, como o processo de desenvolvimento dos modelos. A modelagem é dependente de um sistema, que é o conjunto de componentes e inter-relações, dependendo do objetivo do estudo. Conjunto de objetos, ou elementos, que descrevem as principais características de uma situação real a estudar (PESSOA et al., 1997). A interpretação dada aos fenômenos envolvidos no sistema está intimamente ligada e correlacionada ao nível de exatidão obtida na sua descrição. A simulação inclui os processos necessários para a operacionalização do modelo ou a solução do modelo visando simular o que acontece no sistema (De WIT, 1978).

2.4.2 Aplicações da modelagem

O processo de simulação acompanha a humanidade desde o seu início, devido à necessidade de prever processos ou cenários futuros. Em aspectos ligados ao suprimento de alimentos, a humanidade, mesmo que inconscientemente, já exercitava processos simulatórios, afinal, a simulação e o planejamento são áreas próximas, pois, a partir delas a sobrevivência torna-se possível.

A técnica da modelagem pode ser utilizada para definir as prioridades da pesquisa, além de entender as interações entre o solo-planta-atmosfera (DOURADO NETO et al., 1998). Na agricultura, a simulação é importante para prever os resultados de uma determinada gerência de sistema ou de uma determinada condição ambiental (WU et al., 1996). Além disso, as análises das respostas no crescimento das plantas em função de determinados fatores melhoram a eficiência da produção das culturas e fornecem os rumos das pesquisas. A simulação do crescimento das plantas pelos modelos, que consistem em muitos componentes e níveis de interação (utilizado para ensinar e aprender), são utilizados para a previsão da resposta das plantas a determinada condição climática, como ferramenta de gerência e tomada decisória (RIMMINGTON; CHARLES-EDWARDS, 1987).

Para Boote et al. (1996), modelos são importantes ferramentas para sumarizar o conhecimento científico, auxiliando a tomada de decisão. Modelos são utilizados para o manejo na agricultura, são utilizadas em atividades de planejamento, possuidores de grande potencial didático e orientam e racionalizam o uso de experimentos convencionais. Além disso, os modelos

de simulação são utilizados para verificar teorias e testar hipóteses, melhorar o conhecimento sobre um determinado processo, alimentando bases de dados com as informações obtidas e obter estimativas da produtividade de grãos (MUNAKATA, 1995; BOOTE et al., 1996). Segundo Munakata (1995), os estudos de simulação de crescimento das culturas podem ser definidos em duas linhas: (i) aquela que considera a estrutura do dossel da planta (características para a interceptação da luz); e (ii) a dinâmica da produção de fitomassa seca (crescimento).

2.4.3 Vantagens e limitações da modelagem

As vantagens da utilização de modelos matemáticos, segundo Pessoa et al. (1997), implicam em um crescente aumento no uso, proposição e validação dos modelos, sendo elas: baixo custo, velocidade, completa informação, criação de cenários e proposição de cenários ideais. A instalação, condução, avaliação e análise dos resultados exigem infra-estrutura e mão-de-obra especializada, que fazem com que a investigação experimental seja, muitas vezes, maior que a execução de um programa computacional. Tendo em vista que a aquisição de computadores torna-se acessível, além do fato que durante a vida útil do equipamento esse pode executar inúmeras simulações, enquanto no campo em uma área determinada só é possível executar um experimento. À medida que o problema adquire complexidade e aumenta de proporções a utilização da modelagem adquire maior importância. Apesar de possuir um custo maior, a condução de experimentos não pode ser descartada. A modelagem deve auxiliar na decisão de quais os rumos da experimentação a campo, por exemplo, fazendo com que os recursos sejam melhores alocados e, assim, a qualidade das informações sejam mais relevantes à pesquisa.

Quanto à velocidade, a execução de um experimento que avalie a absorção de uma quantidade de nitrogênio pelas raízes e a sua influência sobre a produtividade pode levar até meses para que seja completado, porém, a simulação desse processo por intermédio de parâmetros de entrada e equações pode levar poucos segundos. Em oito horas de trabalho em um campo experimental, pode-se fazer a aplicação de nitrogênio e capina, por exemplo, enquanto que com este mesmo tempo, é possível simular diversas condições e obter os mais diversos resultados.

Com a execução de um experimento o número de informações é relativamente baixo, pois se restringe ao número de parâmetros avaliados. No entanto, com a simulação, possuímos os valores dos parâmetros de entrada e cada um dos valores calculados no decorrer do processo, até

a obtenção do resultado final. Com a obtenção desse relatório, é possível a visualização total do sistema, evidenciando pontos conflitantes e importantes na condução de novas investigações experimentais. Instalando-se experimento com a cultura de soja com o objetivo de obtenção da produção de grãos; no final do ciclo, cerca de 120 dias, obtém-se o resultado real. Em contrapartida, por intermédio da simulação, verificam-se outros aspectos como índice de área foliar, fração alocada para cada um dos órgãos em determinada época do desenvolvimento relativo, produtividade potencial e deplecionada por intermédio da restrição hídrica, e assim por diante.

A simulação de condições diversas já é bem conhecida. Com ela, existe a possibilidade de criar cenários que ainda não são conhecidos, ou seja, cenários alternativos, muitos deles ainda não explorados em experimentos reais. A construção de condições ideais também é possível, o que em condições experimentais seria muito difícil de acontecer, mesmos que os experimentos sejam cuidadosamente executados. De tal forma, que as pesquisas fiquem direcionadas a fatores relevantes ao desenvolvimento do conhecimento e não aos parâmetros que são irrelevantes.

No entanto, é evidente que toda técnica além das vantagens, apresente suas limitações. Uma boa aplicação de qualquer técnica exige que, além do domínio desta, deve-se ter pleno conhecimento de suas limitações, fazendo o melhor uso dela. Uma das limitações é a validação dos modelos e simuladores já existentes. Esse processo, às vezes, é demorado e requer conhecimento amplo do problema, além da obtenção dos dados em campo. Entretanto, sem a execução dessa etapa, todo resultado obtido por simulação poderá ser seriamente comprometido, repercutindo na obtenção de tendências equivocadas (PESSOA et al., 1997). Na comparação entre modelos analíticos e numéricos, sempre são preferenciais os primeiros. Pois, na maioria das vezes, não apresentam problemas, desde que utilizados dentro das condições impostas a sua elaboração. Quando o problema em estudo possuir mais de uma solução, fica difícil determinar qual delas seria a mais conveniente. Outro aspecto é com relação a confiabilidade e exatidão do modelo empregado. Somente por intermédio de uma seleção das bases de dados usadas para o desenvolvimento do modelo ou em sua aplicação posterior pode-se minimizar o problema (DOURADO NETO et al., 1998). De que forma os dados referentes às variáveis foram coletadas? qual a confiabilidade desses dados? Um modelo é tão preciso e possui confiança de acordo com a base de dados que utiliza em seu desenvolvimento influenciando diretamente a simulação. Boote et al. (1996) citam algumas limitações para a utilização da modelagem. Como o custo de

obtenção dos dados (por ex. fotos de satélites, dados proveniente de instrumentação especializada), a variabilidade espacial (em aplicações na experimentação de campo, a variabilidade do solo é muito grande de um local para o outro, causando diferentes produtividades de grãos e esta área é tratada como única), a técnica para o entendimento de alguns dados de entrada, a variabilidade temporal e a qualidade dos dados (deficiência na calibração dos sensores).

2.4.4 Relações entre as áreas do conhecimento

A eficiência do processo de modelagem depende do conhecimento do modelador que vai desenvolver um modelo matemático. As áreas que dão suporte a modelagem vão depender, sobretudo, de qual o objetivo da modelagem. Mas, algumas áreas do conhecimento na modelagem em agricultura são fundamentais, como, por exemplo, agricultura, fisiologia, matemática, estatística, meteorologia, manejo cultural, ecologia, climatologia, cultura e programação, dentre outras. Dessa forma, existe uma necessidade da existência de equipes multidisciplinares para o desenvolvimento dos modelos, e com isso, a sua ampliação de utilização. Costa (1997) ressalta que o desenvolvimento e a aplicação de modelos de simulação, em conjunto com a experimentação convencional em maior escala em nosso país, é um desafio que devemos seguir e que, sem dúvidas, tornará as atividades científicas mais eficientes.

2.4.5 Componentes do processo de modelagem

Existem diversas formas de representar a seqüência do processo de modelagem, dentre elas, a execução de um fluxograma é fundamental para organizar o conhecimento em uma seqüência lógica. Nesse fluxograma, alguns elementos são fundamentais para que o processo seja executado com qualidade.

O procedimento de modelagem é iniciado por intermédio do entendimento correto dos objetivos ou propósitos do modelo a ser construído. Dessa forma, os objetivos devem ser claros e bem definidos, baseados no conhecimento do problema a ser resolvido. Caso eles sejam amplos, devem ser subdivididos em ordem de prioridade. Os objetivos devem ser suficientemente completos, para que a partir deles, possam ser determinados os parâmetros de entrada, o conjunto

de equações a ser utilizada, a metodologia aplicada e as características dos resultados que serão obtidos.

Muitos pesquisadores não conseguem definir a magnitude do problema a ser resolvido. A subdivisão dos objetivos auxilia nesta etapa, e a partir daí, a execução conforme uma ordenação sistemática. Por intermédio disso, deve-se ter uma seleção da complexidade do trabalho. Por exemplo, a produtividade potencial será deplecionada? Caso afirmativo, os dados referentes à precipitação serão necessários. Um processo estocástico será utilizado? O conhecimento de probabilidade e suas implicações serão necessários.

Quais são os dados disponíveis para execução do trabalho? Para a obtenção de produtividades potenciais são necessárias as temperaturas máxima e mínima, insolação e umidade relativa do ar, dentre outras. Qual a escala em que estes dados se encontram? Mensal, quinzenal ou diária? Isto está relacionado diretamente com a qualidade dos resultados.

Por intermédio do diagrama conceitual, organiza-se o conhecimento em fluxograma, com a ordenação dos conceitos e seqüência lógica dos cálculos.

Um modelo matemático pode ter mais de uma centena de equações e variáveis fixas de entrada (constantes), e estas devem ser revisadas antes de iniciar a execução das rotinas computacionais.

No processo dinâmico de construção do programa computacional, em que as equações são transformadas em linguagem computacional, é aconselhável que os resultados dos cálculos apresentados pelo computador sejam comparados com outros resultados já existentes na literatura, para evitar que os erros não sejam encontrados, devido à complexidade e da magnitude do programa. É um conjunto de atividades necessárias para verificar a precisão dos enunciados e das equações propostas. A verificação corresponde conferência se os algoritmos e os códigos computacionais estão corretos para as definidas relações matemáticas.

A análise sensitiva é o processo de comparação dos resultados das equações com os resultados existentes na literatura. Os resultados devem estar dentro de uma amplitude com aceitação científica. Após a implementação do modelo, pode-se estabelecer a fase de produção dos resultados (calibração). Nessa fase ocorre o estabelecimento dos parâmetros para as entradas e condições internas do sistema, a fim de se verificar a adequação das respostas. Sendo assim, o ajuste dos parâmetros do modelo para a situação em questão. O estágio de 'teste' está relacionado com o estabelecimento da similaridade das respostas do modelo, pela comparação das mesmas

com um conjunto de observações independentes. Uma validação completa pode ser realizada se forem feitos experimentos concomitantes no modelo e no sistema real. Esta etapa muitas vezes não é possível pela complexidade da modelagem. Nessa etapa ocorre a comparação dos dados reais com os dados simulados, mas esse procedimento somente é uma parte da avaliação total do modelo. Essa etapa deve ser realizada com prudência para evitar erros de interpretação (COSTA, 1997).

Pesquisadores de diversas partes do mundo vêm usando vários modelos de estimativa de produtividade de culturas, testando a habilidade na simulação de eventos fenológicos de produção de biomassa (DOURADO NETO, 1999).

Com base nas relações energia-planta, um procedimento mais simples foi desenvolvido por Doorenbos e Kassam (1994) para estimativa do rendimento potencial de diversas culturas. Simulações realizadas com a utilização deste modelo requerem uma quantidade relativamente pequena de dados de entrada, o que facilita sua aplicação (VILLA NOVA et al., 2001).

2.4.6 A modelagem e a estatística

Dentre as diversas áreas que interagem com a modelagem, a estatística é muito utilizada em modelos que conferem uma visão estocástica aos resultados, ou seja, as variáveis utilizadas são descritas em função de uma densidade de probabilidade. Dessa forma, os modelos probabilísticos ou estocásticos, são expressões que envolvem variáveis, parâmetros e constantes matemáticas, juntamente com um ou mais componentes aleatórios resultantes de flutuações imprevisíveis dos dados de observação ou da experimentação. A estatística clássica utiliza parâmetros como média e desvio padrão para representar um fenômeno, e baseia-se na hipótese de que as variações de um local para outro são aleatórias (GOMES, 2002).

A utilização de probabilidade pode ser realizada utilizando-se de três diferentes formas: (i) Simulação de Markov – Essa forma de conferir probabilidade baseia-se nos precedentes do sistema para simular os estados posteriores, representando, assim, uma cadeia de acontecimentos sucessivos. Esse método foi utilizado por Morisawa (1985), para analisar as propriedades topológicas das redes de drenagem. Esse método foi bem aceito e, logo após, foi utilizado para a análise do desenvolvimento das cavernas calcárias, distinguindo as variações aleatórias regionais e locais em perfis longitudinais dos rios do Arizona (CURL, 1959; MELTON, 1962). Além disso, foi utilizado para o desenvolvimento de perfis longitudinais dos cursos d'água, pressupondo que

a temperatura e a altura absoluta acima do nível da base possam ser intercambiadas e que há continuação na geração interna da entropia (LEOPOLD; LANGBEIN, 1962). Stulp (2004) utilizou uma matriz de Markov para analisar a convergência regional dos níveis de produtividade da mão-de-obra na agropecuária do Rio Grande do Sul. Dentre as conclusões do autor, com base na evolução histórica da produtividade da mão-de-obra na agropecuária das regiões do RS (1975-1995), verifica-se que: (a) a classe de nível de produtividade mais alta tende a migrar, no futuro, para as classes de níveis mais baixos, e a de nível mais baixo tende a se manter estável, com aproximadamente o mesmo percentual de regiões; (b) haverá uma redução na participação relativa das regiões na segunda classe e um aumento acentuado na participação na terceira classe;

(ii) Simulação Monte Carlo – Neste caso, o evento simulado é independente dos estados prévios do sistema. Existem poucos estudos que utilizam esse sistema em geomorfologia, porém, é amplamente utilizado em estudos hidrológicos e na análise do processo de difusão da geografia humana. HEUVELINK (1998) formaliza e analisa alguns métodos de propagação de erro para modelagem ambiental e, entre estes, o método de Monte Carlo tem aplicação geral e pode ser usado em modelos com formulações matemáticas não diferenciáveis. Ortiz et al. (2004) descrevem um procedimento de modelagem de fertilidade do solo que integra propriedades químicas do solo utilizando o método de Monte Carlo, de modo a realizar a espacialização das propriedades químicas, foi obtida por procedimento geoestatístico de simulação estocástica, com modelagem das incertezas associadas às estimativas. As incertezas das propriedades químicas foram propagadas para o modelo de fertilidade resultante, possibilitando a geração de mapas de fertilidade condicionados a níveis de risco pré-definidos. Utilizou-se como exemplo, a cultura de soja no Estado de Santa Catarina, considerando as seguintes propriedades químicas do solo: alumínio trocável, potássio e capacidade de troca catiônica. Dentre os resultados, os autores indicam que (a) a utilização do método de Monte Carlo mostra-se vantajosa, pois permite trabalhar com realizações obtidas por processo de simulação estocástica de variáveis aleatórias, o que possibilita representar melhor a variabilidade das variáveis de entrada e, em consequência, a variabilidade do resultado; (b) esse método qualifica o resultado da modelagem por meio das incertezas propagadas das variáveis de entrada. Utilizando-se uma série histórica de seqüência de dias secos (veranicos) evapotranspiração diária. Sousa e Peres (1998) desenvolveram um modelo computacional em linguagem “Turbo Pascal for Windows”, utilizando o método Monte Carlo. Além da simulação da ocorrência de veranicos, também simulou a queda de rendimentos de

determinada cultura. O modelo desenvolvido permite simular a ocorrência de veranicos de diferentes intensidades de duração, bem como o respectivo rendimento relativo, considerando a região e o mês de desenvolvimento da cultura; (iii) Modelos de otimização – Nesse caso, promove-se a maximização ou minimização de alguma força ou critério. Uma aplicação deste tipo de modelo foi utilizada por Frizzone et al. (1997). Esse modelo considerou um conjunto de fatores técnicos que influencia a rentabilidade de um projeto de irrigação. O modelo de programação linear separável foi equacionado genericamente, de forma a indicar o uso racional do recurso hídrico num projeto de irrigação, e foram desenvolvidas equações específicas e aplicadas a um caso, envolvendo o Projeto de Irrigação Senador Nilo Coelho (PSNQ, localizado em Petrolina – PE). Dentre os resultados obtidos, os autores indicam que (a) o modelo de programação linear possibilitou a obtenção de planos ótimos de cultivo e a correspondente alocação de água, podendo ser facilmente adaptado a diferentes situações do meio físico e (b) o modelo de otimização desenvolvido projetou uma receita líquida 52,34% maior que a obtida com o plano de cultivo tradicional do PSNC, considerado, como exemplo, o ano agrícola de 1992.

2.4.7 Caracterização dos elementos climáticos

A caracterização das variáveis climáticas (temperatura média do ar, radiação solar global e a precipitação pluvial) de uma série de anos faz-se necessária para a compreensão dos fatores climáticos, determinando seus padrões de ocorrência e permitindo a previsão de cenários futuros, e auxiliando nos rumos das atividades agropecuárias. Um método simples para a visualização dos dados climáticos é a utilização de histogramas de freqüências, porém, esses são insuficientes para inferir se valores das variáveis se ajustam as distribuições de probabilidade conhecidas. Muitas são as distribuições de probabilidades conhecidas, dentre as que se ajustam a dados discretos estão as distribuições de Bernoulli, Binomial, Binomial Negativa, Hipergeométrica, Geométrica e Poisson. Para o caso de variáveis aleatórias contínuas, têm-se as distribuições Uniforme, Normal, Log-normal, Gama, Valores extremos (Gumbel), Weibull, Exponencial, Beta, Qui-quadrado, t de Student e F de Snedecor, dentre outras.

A utilização das funções de densidade de probabilidade está diretamente ligada à natureza dos dados a que se relacionam. O entendimento do tamanho amostral faz-se necessário, pois alguns tipos de distribuição possuem melhor estimação para pequenas amostras e outras para grandes amostras. O número de parâmetros da equação faz com que as formas assumidas pelas

distribuições sejam as mais variadas e, assim, algumas se enquadram em um maior número de situações que outras. A utilização de determinada distribuição de probabilidade deve respeitar a representatividade dos dados e as estimativas dos seus parâmetros para uma determinada região, sem prejuízo na estimação da probabilidade (CATALUNHA et al., 2002).

Estudos decorrentes da verificação do ajuste de dados de fatores climáticos em relação a distribuições de probabilidade, foram desenvolvidos para a temperatura do ar (MOTA; ROSSKOFF; SILVA, 1999; BURIOL et al., 2000a e 2000b), para radiação solar (BURIOL et al., 2000a e 2001) e para precipitação pluvial (CASTRO, 1996; ÁVILA et al., 1996; BOTELHO; MORAIS, 1999; CATALUNHA et al., 2002; DOURADO NETO et al. 2005).

A verificação do ajuste entre os dados de um determinado elemento do clima a uma distribuição de probabilidade fornece um resumo dos dados de uma série de anos. A partir daí, cada distribuição de frequência apresenta uma forma, a qual pode ser aproximada via a utilização da função densidade de probabilidade com os parâmetros extraídos da amostra em estudo. Segundo Almeida (1995), a utilização ou não de uma distribuição reside na capacidade da mesma estimar os dados observados, com base em seus parâmetros, e essa capacidade é verificada com a aplicação de testes de aderência.

As comparações entre as probabilidades empíricas de uma variável com as probabilidades teóricas estimadas pela função da distribuição de probabilidade, em teste, podem ser verificadas pelos testes de aderência, como o de qui-quadrado, Kolmogorov-Smirnov, Lilliefors (CAMPOS, 1983). Esses testes verificam se valores amostrais podem ser razoavelmente considerados como provenientes de uma população com a distribuição teórica. A diferença entre os testes está no seu poder de rejeitar a hipótese nula (H_0) quando essa for realmente falsa ($1 - \beta$).

Segundo Catalunha et al. (2002), o teste de qui-quadrado é normalmente mais eficaz que o teste de Kolmogorov-Smirnov, e esse é menos eficaz que o teste de Lilliefors que possuem uma limitação que é a especificidade do teste para verificar a aderência dos dados a distribuição normal (CAMPOS, 1983). A limitação do teste de qui-quadrado se refere à frequência de uma classe não pode ser inferior a cinco e os dados são agrupados em classes perdendo informações. No caso desse tipo de estudo, são raros os casos que relacionam a distribuição de densidade de probabilidade com dados diários em séries semelhantes. O mais frequente é o uso de dados mensais, quinzenais ou decendiais. Dessa forma, por intermédio da utilização do teste de

Kolmogorov-Smirnov, que pode ser realizado tanto para dados agrupados quanto para os diários, tem-se uma melhor caracterização das variáveis em estudo (CAMPOS, 1983).

2.4.8 A modelagem na cultura de soja

A cultura de soja possui alguns exemplos de aplicações práticas da modelagem no Brasil, porém, a pesquisa nesse sentido não é muito ampla e necessita ser intensificada, devido a grande importância da cultura para a economia. Com o objetivo de estimar a produtividade potencial de grãos de quatro genótipos de soja, Camargo (1984) utilizou variáveis meteorológicas e propôs a seguinte equação:

$$Y_{est} = Y_{pot} \cdot F_{ter} \cdot F_{def} \cdot F_{exc} \quad (2)$$

em que Y_{est} se refere à produtividade estimada; Y_{pot} à produtividade potencial do genótipo; F_{ter} ao fator de redução associado aos graus-dias acumulados (fator térmico); F_{def} e F_{exc} ao fator de redução associado à deficiência e excesso hídrico, respectivamente. O modelo proposto apresentou as estimativas de produtividade de soja satisfatórias, verificados por intermédio dos coeficientes de determinação da regressão entre os dados observados e os estimados, que variaram de 0,76 a 0,87 para os quatro genótipos estudados.

Liu e Liu (1986) também desenvolveram modelos de previsão de produtividade de soja para o estado de Minas Gerais. O modelo desenvolvido por esses autores utilizou dados mensais de temperatura máxima e mínima, umidade relativa, precipitação, evapotranspiração potencial, excesso e deficiência hídrica, além da interação desses parâmetros. A partir desse modelo selecionaram-se dois modelos, o primeiro inclui os parâmetros tendência tecnológica, deficiência e excesso hídricos, temperaturas máxima e mínima e a interação de umidade relativa e temperatura mínima. A aplicação desse modelo possibilitou a previsão da colheita com antecedência de um mês. O segundo modelo, que inclui os parâmetros precipitação, evapotranspiração, excesso e deficiência hídricos, temperatura mínima, umidade relativa, interação de chuva e temperatura máxima e interação de umidade relativa, possui a vantagem de existir valores de coeficientes de determinação e os níveis de significância dos parâmetros mais elevados. Os erros de previsão variam de 0,1 a 5,6% no primeiro modelo e de 0,1 a 8,3% no segundo, mediante teste de um período de 12 anos.

2.4.9 Classificação dos modelos

A modelagem pode ser aplicada em diversas situações que exige a construção de diferentes tipos de modelos, sendo que estes recebem classificações devido as suas características. Os modelos agroclimáticos são classificados da seguinte forma, segundo Baier (1979): (i) modelos de simulação de crescimento das culturas; (ii) modelos de análise planta-atmosfera e (iii) modelos estatísticos empíricos.

Barros (1998) classificou os modelos em matemático e de simulação. O primeiro se refere a representações matemáticas de um fenômeno, enquanto que o segundo engloba um ou mais modelos matemáticos, representando fenômenos mais complexos. Os modelos matemáticos referem a representações matemáticas de um fenômeno, podendo ser de três tipos: (i) empíricos, baseados em dados observados; (ii) estocásticos, em que o processo é descrito por intermédio das leis de probabilidade e (iii) mecanísticos, onde as leis da física, química e biologia influenciaram no processo, sendo os mais versáteis dentro dos tipos de modelos matemáticos (PAUSTIAN et al., 1992). A utilização de vários modelos matemáticos faz com que os modelos de simulação sejam mais completos (ADDISCOTT, 1993), sendo subdivididos em (i) determinísticos, em que um conjunto de eventos leva a um resultados único e definido; e (ii) estocásticos, em que a incerteza é considerada na estrutura, levando em consideração as leis da probabilidade e estatística. Essas duas categorias podem possuir subdivisões conforme características pecuniárias de cada caso. Sendo citados como (i) mecanísticos, que procura descrever os mecanismos envolvidos no processo e (ii) funcionais, que descrevem apenas os aspectos gerais do processo.

Segundo Muchov et al. (1991), os modelos de simulação e previsão de produtividades de culturas permitem fazer simulações de longo prazo, sendo realizadas geralmente a um baixo custo, utilizando-se características do solo e práticas de manejo da cultura durante o período avaliado com os dados climatológicos históricos disponíveis para determinado local.

A amplitude de alcance dos modelos de simulação irá influenciar decisivamente na precisão das produtividades, sendo assim, a utilização de grandes áreas para estimação de produtividades de grãos será uma característica positiva e favorável no sentido de melhorar a precisão dos modelos (LOZARDA; ANGELOCCI, 1999).

3 MATERIAL E MÉTODOS

3.1 Obtenção das séries históricas das variáveis climáticas

Os dados referentes às variáveis climáticas (temperatura, insolação e precipitação) foram obtidos no Departamento de Ciências Exatas (Esalq/USP), sendo originados pelo Departamento de Águas e Energia Elétrica de São Paulo (DAEE) e Instituto Agrônomo de Campinas (IAC), Sistema Meteorológico do Paraná (SIMEPAR - <http://www.simepar.br/>, 2006), Instituto Nacional de Meteorologia (INMET) e SIMEPAR. Na Tabela 32 e Tabela 33 estão resumidas e relacionadas às cidades e as séries históricas obtidas. Os dados de temperatura e chuva referentes a 33 municípios (28 municípios paulistas e 5 municípios de estados vizinhos) estão representados na Figura 1.

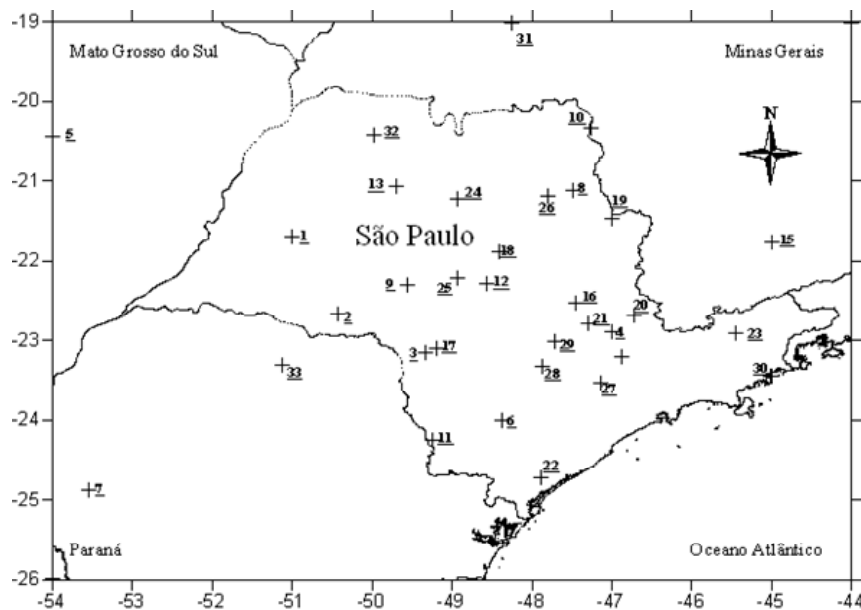


Figura 1 - Distribuição espacial dos locais avaliados: Adamantina (1), Assis (2), Ataliba Leonel (3), Campinas (4), Campo Grande (5), Capão Bonito (6), Cascavel (7), Cravinhos (8), Gália (9), Guairá (10), Itararé (11), Jaú (12), José Bonifácio (13), Jundiaí (14), Lavras (15), Limeira (16), Manduri (17), Matão (18), Mococa (19), Monte Alegre do Sul (20), Nova Odessa (21), Pariquera-Açu (22), Pindamonhangaba (23), Pindorama (24), Piracicaba (25), Ribeirão Preto (26), São Roque (27), Tatuí (28), Tietê (29), Ubatuba (30), Uberlândia (31), Votuporanga (32) e Londrina (33)

3.2 Obtenção da radiação fotossinteticamente ativa (q) a partir da insolação

A estimativa da radiação fotossinteticamente ativa foi obtida por intermédio dos valores de insolação diária ($h.d^{-1}$), sendo a sua estimativa obtida por intermédio das equações abaixo. A declinação solar (δ , radianos) depende somente da posição relativa entre a Terra e o Sol, podendo ser calculada conforme a equação apresentada por Pereira et al. (2002).

$$\delta_j = 23,45 \cdot \text{sen} \left[\left(\frac{360}{365} \right) (J - 80) \right] \quad (3)$$

em que J é o número de ordem do dia do ano (dia Juliano).

O cálculo do ângulo horário do nascer do solo (H_j) é dado por:

$$H_j = a \cos(-\text{tg}(\Phi) \text{tg}(\delta_j)) \quad (4)$$

em que Φ é a latitude do local e δ_j é a declinação solar.

O fotoperíodo (N , $h.d^{-1}$) refere-se ao intervalo entre o nascer e o pôr do sol em um determinado dia, também chamado de duração do dia, calculado pela seguinte equação:

$$N_j = \frac{2 \cdot H_j}{15} \quad (5)$$

A irradiância solar extraterrestre diária que atinge uma superfície horizontal no topo da atmosfera (Q_o , $MJ.m^{-2}.d^{-1}$), é função da latitude e da declinação solar.

$$Q_{o_j} = 37,6 \cdot \left[1 + 0,033 \cdot \cos \left(NDA_j \cdot \frac{360}{365} \right) \right] \cdot \left[\left(\frac{\pi}{180} \right) H_j \cdot \text{sen} \Phi \cdot \text{sen} \delta_j + \cos \Phi \cdot \cos \delta_j \cdot \text{sen} H_j \right] \quad (6)$$

A estimativa da irradiância solar global diária (Qg_j , $MJ.m^{-2}.d^{-1}$) é função do Q_{o_j} , da absorção e da difusão atmosférica e da insolação, e pode ser calculado da seguinte forma:

$$Qg_j = Q_{o_j} \cdot \left[0,29 \cdot \cos \Phi + 0,52 \cdot \frac{n_j}{N_j} \right] \quad (7)$$

em que n_j é a insolação no dia juliano j .

A radiação fotossinteticamente ativa (q_j , $MJ.m^{-2}.d^{-1}$)¹ foi estimada por intermédio da equação apresentada por Assunção (1994).

$$q_j = \frac{Qg_j}{N_j \cdot 60} \cdot \left(0,5 - 0,1 \cdot \frac{n_j}{N_j} \right) \quad (8)$$

¹ 1MJ equivale a 238.662,345287 Calorias. Fonte: <http://www.ipem.sp.gov.br/> (2006).

3.3 Aplicação do teste do Kolmogorov-Smirnov

O teste de Kolmogorov-Smirnov verifica a adaptação específica e conhecida distribuição $F(X)$, a dados provenientes de uma distribuição desconhecida $F_0(X)$. O teste é baseado no módulo da diferença entre a probabilidade observada e a estimada, sendo que essa é comparada com um valor tabelado de acordo com o número de observações (CATALUNHA et al., 2002). A hipótese da nulidade verifica se é razoável estudar os dados amostrais por intermédio de uma distribuição de probabilidade conhecida $F(X)$.

Para a realização do teste, devem ser consideradas: $F(X)$, que é a proporção de valores esperados inferiores ou iguais a X ; $S(X)$, que é a proporção de valores observados inferiores ou iguais a X ; e a verdadeira função de distribuição de X , que nos é desconhecida. Deve ser observado se $S(X)$ é uma função empírica de distribuição, sendo um estimador de $F_0(X)$. Define-se:

$$D = |F(X) - S(X)| \quad (9)$$

Utilizou-se o teste de Kolmogorov-Smirnov a 5% de probabilidade de erro para a hipótese: $H_0: F \equiv F_0$ vs $H_\alpha: F \neq F_0$, para pelo menos um valor de X , rejeitando H_0 se $D \geq d$. Nesse caso, foram utilizados os valores de d apresentados em Campos (1983). Para o número de amostras superior a 100, utilizou-se a seguinte aproximação:

$$d = \frac{1,35}{\sqrt{n}} \quad (10)$$

em que n é o número de anos da série histórica (amostra).

A verificação da adequação das distribuições de probabilidade foi realizada para todos os dias do ano para temperatura do ar média, precipitação e radiação fotossinteticamente ativa em todas as localidades.

3.3.1 Distribuições de probabilidade avaliadas

Dentre as diversas distribuições de probabilidades conhecidas de variáveis aleatórias, discretas ou contínuas, a distribuição normal de probabilidades é a mais importante sob a ótica do conhecimento agrônomo. Isso ocorre devido a um grande número de fenômenos poderem ser estudados por intermédio dessa distribuição. Outro fato relevante, são as médias de variáveis aleatórias que seguem outras distribuições (discretas ou contínuas) e tendem para a distribuição

normal à medida que o número de observações aumenta (STORCK et al., 2001). Se X é uma variável aleatória contínua, então essa variável possui distribuição normal de probabilidade se:

$$f_X(x, \mu, \sigma^2) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right], \quad (-\infty \leq x \leq \infty) \quad (11)$$

em que os parâmetros μ e σ^2 são, respectivamente, a média e a variância.

Os principais cálculos de probabilidades são: (i) a probabilidade de X estar entre os limites X_1 e X_2 é igual a $P(X_1 \leq X \leq X_2) = \int_{x_1}^{x_2} f(x) dx$; (ii) a probabilidade de X ser menor do que X_1 é

igual a $P(X \leq X_1) = \int_{-\infty}^{x_1} f(x) dx$; (iii) a probabilidade de X ser maior do que X_1 é igual a

$P(X \geq X_1) = \int_{x_1}^{\infty} f(x) dx$. Essas integrais (i, ii e iii) são de difícil solução, pois exigem a

decomposição em séries e a construção de tabelas, onde $f(x)$ depende de μ e da σ^2 , tornando-se inviável. Então usa-se a variável padronizada ou reduzida, conforme segue:

$$Z = \frac{X - \mu}{\sigma} \quad (12)$$

Sendo que a variável reduzida Z possui distribuição normal com média zero e variância um, $Z \sim N(0,1)$.

A função densidade de probabilidade da variável reduzida é dada por:

$$f_Z(Z) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}Z^2\right), \quad (-\infty \leq z \leq \infty) \quad (13)$$

Sendo que a distribuição de Z não depende de μ e σ^2 (média é sempre zero e variância sempre um), pode-se construir tabelas para diferentes limites de Z ou áreas (probabilidades) sob a curva, com ampla aplicação em cálculos de probabilidades. A probabilidade $P(X_1 \leq X \leq X_2)$ é equivalente a $P(Z_1 \leq Z \leq Z_2)$, onde:

$$Z_1 = \frac{X_1 - \mu}{\sigma} \quad (14)$$

$$Z_2 = \frac{X_2 - \mu}{\sigma} \quad (15)$$

As propriedades da distribuição normal são: (i) a função densidade de probabilidade $f(x)$ é simétrica em relação à média $X=\mu$ e $f(z)$ é simétrica em relação à média $Z=0$; (ii) $f(x)$ tem ponto de máximo para $X=\mu$ e $f(z)$ para $Z=0$; (iii) $f(x)$ tende para zero, se x tende para $\pm \infty$ e $f(z)$ tende

para zero, se z tende para $\pm \infty$; (iv) $f(x)$ tem dois pontos de inflexão, cujas abscissas valem $\mu - \sigma^2$ e $\mu + \sigma^2$, sendo que para $f(z)$ as abscissas valem, respectivamente, -1 e 1.




Figura 2 - Função densidade de probabilidade normal e probabilidade acumulada

Geralmente, aplica-se a distribuição exponencial a dados com forte assimetria, ou seja, os dados possuem uma tendência a formar um “J” invertido. A função densidade de probabilidade é descrita a seguir (KITE, 1978).

$$f(x) = \frac{\exp\left(-\frac{x}{\bar{x}}\right)}{\bar{x}} \quad (16)$$

Sendo que a função de distribuição acumulada é representada por:

$$F(x) = \int_0^{\infty} f(x)dx = 1 - \exp\left(-\frac{x}{\bar{x}}\right) \quad (17)$$

Nesse caso, o único parâmetro da distribuição (λ) é estimado pelo inverso da média.




Figura 3 - Função densidade de probabilidade exponencial (a), função acumulativa (b), gráficos gerados a partir de uma simulação aleatória de 1000 valores, com média 0,79, variância 0,61 e Lambda (λ) igual a 2

A distribuição log-normal assume que os logaritmos das variáveis aleatórias são normalmente distribuídos. Mirshawka (1971) descreve a densidade de probabilidade para dois parâmetros na seguinte equação.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{[\ln(x-\mu)]^2}{2\sigma^2}\right] \quad (18)$$

em que x se refere ao valor da variável aleatória; μ é a média dos logaritmos da variável aleatória X ; σ é o desvio padrão dos logaritmos da variável aleatória X .

Para encontrar a probabilidade de uma variável aleatória (X), tendo distribuição Log-Normal, assumir valores entre a e b ($a \leq X \leq b$), utilizando a seguinte expressão:

$$P(a \leq X \leq b) = \int_a^b \frac{1}{(x-a)\sigma\sqrt{2\pi}} \exp\left[-\frac{[\ln(x-a)-\mu]^2}{2\sigma^2}\right] dx = 1 - \alpha \quad (19)$$

em que a pode ser zero, quando considerada a distribuição normal com dois parâmetros, ou um valor mínimo da série, quando se consideram três parâmetros; b pode ser o valor da variável aleatória quando se considera a probabilidade cumulativa de ocorrência daquele valor (HASTINGS e PEACOCK, 1975).




Figura 4 - Função densidade de probabilidade log-normal (a), função acumulativa (b), gráficos gerados a partir de uma simulação aleatória de 1000 valores, com média 3,05, variância 18,89

Uma variável aleatória contínua \mathbf{X} ($X > 0$) distribui-se segundo a distribuição Gama de parâmetros α ($\alpha > 0$) e β ($\beta > 0$), se sua função de densidade de probabilidade é dada por:

$$f(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-\frac{x}{\beta}} \quad (20)$$

em que $P(X \leq x)$ refere-se à probabilidade de ocorrer um valor $X \leq x$ (probabilidade de ocorrer uma quantidade de precipitação pluvial igual ou inferior a x , por exemplo); \mathbf{X} se refere a variável aleatória contínua; α é o parâmetro de forma da variável aleatória \mathbf{X} ; β ao parâmetro de escala da variável aleatória \mathbf{X} ; e ao número de Neper (2,718...); x é o valor que se deseja verificar pela distribuição Gama; $\Gamma(\alpha)$ é a função Gama incompleta, que pode ser assim definida:

$$\Gamma(\alpha) = \int_0^{\infty} e^{-x} \cdot x^{\alpha-1} dx \quad (21)$$

Os parâmetros α e β foram obtidos por intermédio de:

$$12A\alpha^2 - 6\alpha - 1 = 0 \quad (22) \quad \hat{\alpha} = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) \quad (23)$$

$$\hat{\beta} = \frac{\bar{x}}{\hat{\alpha}} \quad (24) \quad A = \ln(\bar{x}) - \ln(\bar{x}_g) \quad (25)$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (26)$$

$$\bar{x}_g = \frac{1}{n} \sum_{i=1}^n \ln(x_i) \quad (27)$$

em que \bar{x} se refere à média aritmética das observações; \bar{x}_g é a média geométrica das observações; x_i ao i -ésimo valor diário da variável e n ao número de observações.

Abramowitz e Stegun (1972) definem o seguinte polinômio aproximador para o cálculo da função gama, para um intervalo de $1 \leq \alpha \leq 2$, da seguinte forma:

$$\Gamma(\alpha) = 1 + a_1x + a_2x^2 + a_3x^3 + a_4x^4 + a_5x^5 + a_6x^6 + a_7x^7 + a_8x^8 \quad (28)$$

em que $x = \alpha - 1$; a_1 : - 0,577191652; a_2 : + 0,988205891; a_3 : - 0,897056937; a_4 : + 0,918206857; a_5 : - 0,756704078; a_6 : + 0,482199394; a_7 : - 0,193527818; a_8 : + 0,035868343

$$\Gamma(\alpha) = \Gamma(n + N) = \Gamma(n + 1) \prod_{k=1}^{N-1} (n + N - k) \quad (29)$$

Com $\alpha > 2$, em que n é a parte fracionária de α ; N a parte inteira de α , sendo $N \leq 2$; $k = 1, 2, 3, \dots, N$.




Figura 5 - Função densidade de probabilidade gama (a), função acumulativa (b) gráficos gerados a partir de uma simulação aleatória de 1000 valores, α e β igual a 5,5, com média 31,12, variância 172,99

A distribuição de Weibull foi proposta originalmente pelo pesquisador sueco Waloddi Weibull (1939)², em estudos referentes ao tempo de falha, devido à fadiga de metais. Mais tarde, foi publicado o estudo denominado de “*A Statistical Distribution of Wide Applicability*”, onde o modelo foi aplicado para tipos distintos de amostras, como a resistência a deformação e fadiga de aços, comprimento de fibras de algodão, estatura de homens adultos, dentro outros (WEIBULL, 1951). Dentre as aplicações da distribuição de Weibull estão à descrição do tempo de vida de sistemas formados por vários componentes, cuja falha ocorre quando um primeiro componente falhar. A distribuição de Weibull é bastante flexível na descrição de processos aleatórios e permite grande variedade de formas, sendo que todas apresentam uma propriedade básica que é a função da taxa de falha monotônica, podendo ser decrescente, crescente ou constante.

A função de distribuição de probabilidade de Weibull é apresentada de diversas formas, podendo ser apresentada como:

$$f(x) = \frac{\alpha}{\beta} \left(\frac{x - x_0}{\beta} \right)^{\alpha-1} \exp \left(- \left(\frac{x - x_0}{\beta} \right)^\alpha \right) \text{ para } x \geq x_0 \quad (30)$$

em que x é a variável aleatória, $x_0 \geq 0$; $\beta > 0$ e $\alpha > 0$ são os parâmetros da distribuição.

Nessa forma, chama-se a distribuição de Weibull com três parâmetros. Sendo a sua função acumulada dada por:

$$F(x) = \int_0^x f(x) dx = 1 - \exp \left(- \left(\frac{x - x_0}{\beta} \right)^\alpha \right) \quad (31)$$

A distribuição de Weibull com dois parâmetros é representada por:

$$F(x) = \int_0^x f(x) dx = 1 - \exp \left(- \left(\frac{x}{\beta} \right)^\alpha \right) \quad (32)$$

Essa distribuição é utilizada em várias situações, devido à íntima relação dos seus parâmetros com o desempenho da distribuição. O parâmetro x_0 é chamado de parâmetro de posição, pois controla a posição da curva sobre o eixo das abscissas. Quando x_0 é igual à zero (menor valor da amostra), a distribuição inicia-se neste valor, surgindo um caso especial, que é a distribuição de Weibull com dois parâmetros. O parâmetro β é o de forma, sendo que esse controla as dimensões que a curva assume, dada uma forma constante. Na medida em que β

² Weibull, W. A statistical theory of the strength of material. *Proc. Roy. Swedish Inst. Eng. Res.* 151:1, 1939.

aumenta, a curva se torna mais dispersa, isso pode ser facilmente notado quando a distribuição assume a forma de sino. O parâmetro α é chamado de parâmetro de escala, que controla a grande variedade de forma que a distribuição pode assumir. Quando esse parâmetro é maior ou igual a um, a distribuição assume a forma de J invertido. Para valores entre 1 e 3,6 a distribuição torna-se possivelmente assimétrica, tomando a forma de um sino invertido, praticamente simétrica e semelhante à distribuição normal. À medida que o valor passa de 3,6 e tende para o infinito, a distribuição torna-se negativamente assimétrica, tendendo a uma forma extremamente leptocúrtica.

A função densidade cumulativa (dois parâmetros) pode ser transformada em uma equação linear da seguinte forma:

$$F(x) = 1 - e^{-\left(\frac{x}{\beta}\right)^\alpha} \quad (33) \quad 1 - F(x) = e^{-\left(\frac{x}{\beta}\right)^\alpha} \quad (34)$$

$$\ln(1 - F(x)) = -\left(\frac{x}{\beta}\right)^\alpha \quad (35) \quad \ln\left(\frac{1}{1 - F(x)}\right) = \left(\frac{x}{\beta}\right)^\alpha \quad (36)$$

$$\ln\left[\ln\left(\frac{1}{1 - F(x)}\right)\right] = \alpha \ln\left(\frac{x}{\beta}\right) \quad (37) \quad \ln\left[\ln\left(\frac{1}{1 - F(x)}\right)\right] = \alpha \cdot \ln x - \alpha \cdot \ln(\beta) \quad (38)$$

Dessa forma os parâmetros serão estimados por:

$$RM = \frac{k_i - 0,3}{\sum k_n + 0,4} \quad (39)$$

em que k_i é o número de ordem da variável e k_n é o último número de ordem das variáveis.

$$I = \frac{1}{1 - RM} \quad (40) \quad Y = \ln\left[\ln\left(\frac{1}{1 - I}\right)\right] \quad (41) \quad X = \ln(x_i) \quad (42)$$

Será calculada uma regressão linear simples entre X e Y e então serão estimados os parâmetros de forma (β) e de escala (α).

$$\beta = \frac{\sum_{i=1}^n x_i y_i - \frac{\sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n}}{\sum_{i=1}^n x_i^2 - \frac{\left(\sum_{i=1}^n x_i\right)^2}{n}} \quad (43)$$

$$a = \bar{y} - \beta \cdot \bar{x} \quad (44)$$

$$\alpha = \text{Exp}^{\frac{-a}{\beta}} \quad (45)$$

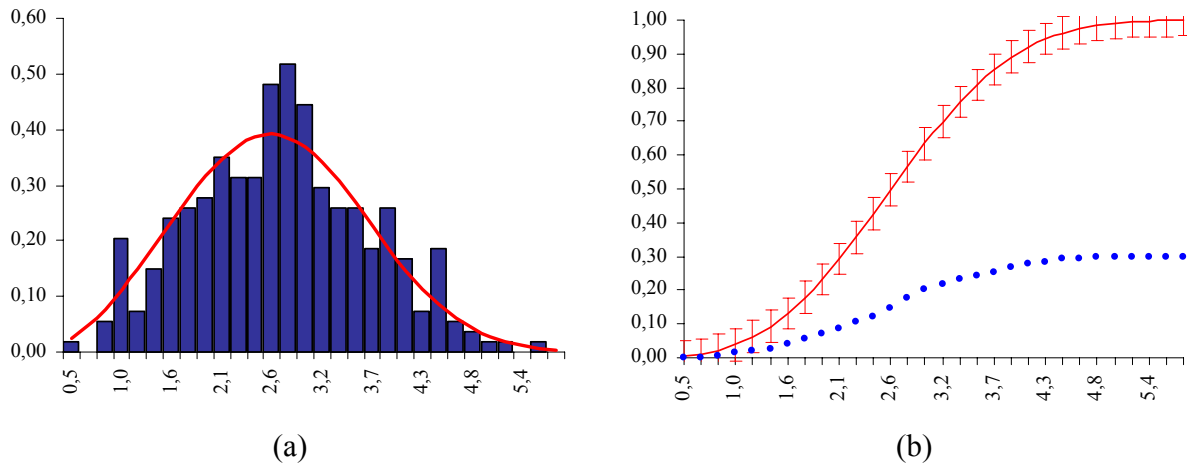


Figura 6 - Função densidade de probabilidade Weibull (a), função acumulativa (b) gráficos gerados a partir de uma simulação aleatória de 1000 valores, α e β igual a 3,5, com média 2,67, variância 0,927

3.4 Distribuição normal bivariada

Como as variáveis radiação fotossinteticamente ativa e temperatura são correlacionadas, possuindo uma relação de dependência, pode-se obter por intermédio de seus parâmetros (média, variância e correlação) um conjunto de valores simulados, cujos parâmetros sejam muito próximos aos parâmetros originais. Os parâmetros do novo conjunto de valores serão cada vez mais próximos dos valores originais à medida que se aumentam o número de simulações ou o tamanho da amostra. Dessa forma, cada dia do ano possui os parâmetros anteriormente citados para as duas variáveis. Com isso, serão simulados 1000 valores de radiação fotossinteticamente ativa e temperatura, para cada dia Juliano. A partir do par simulado, serão calculados 1000 valores de assimilação de dióxido de carbono, que resultará no mesmo número de produtividades potenciais e deplecionadas. Para uma correta simulação, deve-se observar a relação de dependência entre as variáveis. No presente caso, deve-se simular o fator do clima que ocorre primeiro, ou seja, a radiação fotossinteticamente ativa, que por sua vez, desencadeia a temperatura, que deve ser a última a ser simulada.

3.4.1 Função densidade de probabilidade da distribuição normal bivariada

Sejam X_1 e X_2 duas variáveis aleatórias contínuas, essas variáveis possuem distribuição normal bivariada se:

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp(t) \quad (46)$$

$$t = \left\{ -\frac{1}{2(1-\rho^2)} \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 - 2\rho \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right] \right\}, \quad (-\infty \leq x_1, x_2 \leq \infty) \quad (47)$$

em que os parâmetros μ , σ^2 e ρ são a média, a variância e a correlação, respectivamente, entre as variáveis:

$$\mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} \quad (48)$$

em que μ_1 é a radiação fotossinteticamente ativa média e μ_2 é a temperatura média.

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{bmatrix} \quad (49)$$

em que σ_1^2 é a variância da radiação fotossinteticamente ativa, σ_2^2 é a variância da temperatura, ρ é a correlação e $\rho\sigma_1\sigma_2$ é a covariância entre as variáveis (MORRISON, 1990).

As propriedades da função distribuição de probabilidade normal bivariada são as seguintes: (i) $f(x_1, x_2)$ é a função densidade de probabilidade; (ii) a variável x_1 possui distribuição normal (μ_1, σ_1^2) e x_2 possui distribuição normal (μ_2, σ_2^2) ; e (iii) ρ é o coeficiente de correlação entre x_1 e x_2 .

As variáveis padronizadas ou reduzidas z_1 e z_2 , são apresentadas a seguir:

$$z_1 = \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \quad (50) \quad z_2 = \left(\frac{x_2 - \mu_2}{\sigma_2} \right) \quad (51)$$

$$f(z_1, z_2) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp \left[-\frac{1}{2(1-\rho^2)} (z_1^2 - 2\rho z_1 z_2 + z_2^2) \right] \quad (52)$$

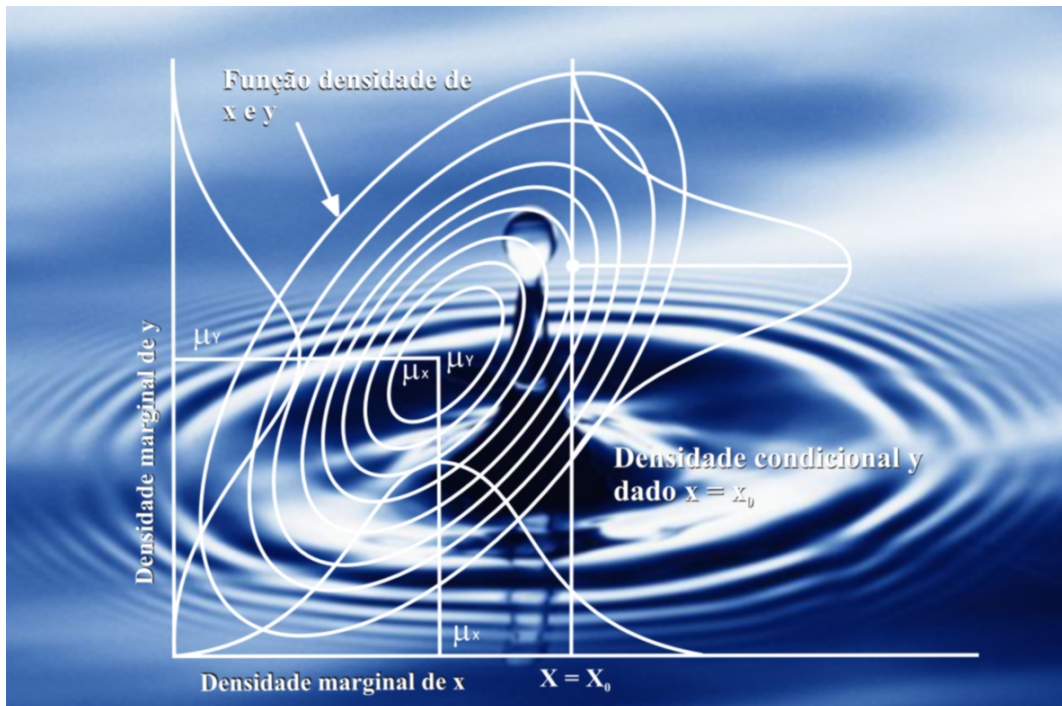


Figura 7 - Função densidade de probabilidade x e y , densidade marginal de y e x , densidade condicional y , dado $x = x_0$ e média da variável X (μ_x) e Y (μ_y)

3.4.2 Distribuição uniforme (ou retangular)

A distribuição uniforme, ou retangular, é aquela cuja variável aleatória contínua admita uma distribuição constante dentro de um determinado intervalo (a, b) (BRESSAN, 2002; MARTINS, 2003; MORETTIN; BUSSAB, 2003). A função densidade é dada por:

$$f(x) = \begin{cases} \frac{1}{(b-a)} & \text{Se } a \leq X \leq b \\ 0 & \text{Se } X < a \text{ ou } X > b \end{cases} \quad (53)$$

A função de distribuição é dada por:

$$F(x) = \begin{cases} 0 & \text{Se } X < a \\ \frac{(X - a)}{(b - a)} & \text{Se } a \leq X \leq b \\ 1 & \text{Se } b < X \end{cases} \quad (54)$$

A partir dos dados da distribuição uniforme, pode-se estimar a média e a variância da seguinte forma:

$$E(X) = \frac{(a+b)}{2} \quad (55) \quad \text{Var}(X) = \frac{(b-a)^2}{12} \quad (56)$$

Uma variável aleatória para ser considerada com distribuição uniforme deve satisfazer determinadas condições, sendo elas (i) uniformemente distribuída no intervalo que verifica as condições e (ii) uma sucessão destas variáveis revela independência estatística (MARTINS, 2003). Dessa forma, sendo X uma variável aleatória com distribuição uniforme entre a e b , $X \cap U(a, b)$, então:

$$F(x) = \int_a^x \frac{1}{b-a} dt = \frac{x-a}{b-a} \quad \text{Para } a \leq x \leq b \quad (57)$$

ou seja:

$$u = F(x) \quad (58)$$

$$u = \frac{x-a}{b-a} \quad (59)$$

$$x = a + (b - a)u \quad (60)$$

A geração de x deve ser antecedida pela geração de um número aleatório U , da seguinte forma:

$$X = a + (b - a)U \quad (61)$$

O gráfico da função densidade de probabilidade da distribuição uniforme é apresentado a seguir.




Figura 8 - Função densidade de probabilidade uniforme (a), função acumulativa (b). Gráficos gerados a partir de uma simulação aleatória de 1000 valores, com média 51,91, variância 752,30

A simulação de uma variável aleatória seguiu o Método Monte Carlo, que pode simular qualquer processo cujo andamento dependa de fatores aleatórios. A essência da simulação Monte Carlo consiste em estabelecer uma distribuição de probabilidade (modelo) ao qual responde a uma variável aleatória (tempo ou custo) para o risco analisado. Além disso, amostrar essa variável aleatória um número suficientemente grande de vezes, para que se possam realizar interações.

O método Monte Carlo consiste em gerar aleatoriamente sucessivas amostras, que serão testadas contra um modelo estatístico, que vem a ser uma distribuição de probabilidade para um determinado risco. Nesse caso, o erro para a estimativa é inversamente proporcional ao número de interações. O erro total é dado por:

$$\varepsilon = \frac{3\sigma}{\sqrt{NuI}} \quad (62)$$

em que σ é o desvio padrão da variável aleatória e NuI é o número de interações.

A geração de números aleatórios pode ser realizada manualmente, porém, em trabalhos que exijam um maior número de cálculos, o uso de softwares estatísticos é frequentemente utilizado. Existem diferentes softwares no mercado que realizam a geração de números aleatórios (ou pseudo-aleatórios). Porém, alguns possuem algumas restrições, como por exemplo, o MS

Excel®, que apresenta a função ALEATORIO() para gerar um número aleatório com distribuição uniforme (0, 1). Nesse caso, a geração do número pseudo-aleatório não é tida como confiável por alguns autores, como L'Ecuyer (2001) e Apigian e Gambille (2004).

Apesar disso, a geração de números aleatórios por intermédio do Excel® pode ser realizado pela adição de um suplemento desenvolvido por Makoto Matsumoto e Takij Nishimura e comparativamente aos softwares tradicionais que realizam essa função, não há perda de qualidade na geração, sendo descrito em Matsumoto e Kurita (1992); Matsumoto e Nishimura (2002); Matsumoto e Kurita (1994); Matsumoto e Kurita (1996) e Matsumoto e Nishimura (1998).

3.5 Verificação da homogeneidade espacial e temporal

A partir da série temporal diária dos locais, calculou-se a média mensal para todos os meses do ano, obtendo-se diferentes séries temporais (**n** locais x 12 meses), para cada variável. Para as variáveis temperatura (mínima, máxima e média), foram utilizados dados de 23 estações meteorológicas, e onde foi calculado a temperatura média do ar para todos os meses do ano (12 meses). Foram obtidas 276 séries temporais (23 estações x 12 meses) para cada variável, que totalizaram 552 séries temporais, com o número de anos variável em cada estação. A homogeneidade das variâncias entre os meses do ano (variabilidade temporal, 12 variâncias), em cada um dos 23 locais (23 testes), foi verificada por intermédio do teste de Bartlett (STEEL et al., 1997). Assim, como a variabilidade entre os locais (23 variâncias – variabilidade espacial), dentro de cada um dos 12 testes.

No caso das variáveis insolação, radiação solar e radiação fotossinteticamente ativa utilizou-se dados diários dos 18 locais, calculou-se a média mensal, para todos os meses do ano, obtendo-se 216 séries temporais (18 locais x 12 meses) para cada variável, totalizando, assim, 432 séries temporais, com o número de anos variável em cada estação. Estimaram-se as variâncias entre os anos para cada um dos 18 locais e 12 meses. Nestas variâncias foi aplicado o teste de Bartlett (STEEL et al., 1997) a 5% de probabilidade de erro, entre os meses do ano (variabilidade temporal, 12 variâncias) em cada um dos 18 locais (18 testes) e, também, entre os locais (18 variâncias – variabilidade espacial), dentro de cada um dos 12 meses do ano.

Utilizou-se a análise de agrupamento (Cluster Analysis) para identificar regiões e meses climaticamente homogêneos quanto às temperaturas mínimas, máximas, média, insolação,

radiação solar, radiação fotossinteticamente ativa e chuva. O método empregado foi o hierárquico aglomerativo de Ward (1963), onde a medida de dissimilaridade foi representada pela distância euclidiana (EVERITT; DUNN, 1991), podendo ser obtida pela seguinte equação:

$$d_e = \left[\sum_{j=1}^n (P_{p,j} - P_{k,j})^2 \right]^{0,5} \quad (63)$$

em que d_e é a distância euclidiana; P_{pj} e P_{kj} são as variáveis quantitativas j dos indivíduos p e k , respectivamente.

Pela utilização do método de Ward, existe a minimização da soma de quadrados de desvios, reduzindo assim, a dissimilaridade de maneira a formar grupos. Por intermédio do procedimento são formados grupos, onde a solução resultante possua a menor soma de quadrados dos desvios dentro dos grupos. Primeiramente, considera-se todas as possibilidades de formação de grupos, e os dois que resultarem em menor aumento na soma de quadrados dos desvios, são agrupados. Esse procedimento é repetido até que todos os grupos formem um único, de forma a reunir todos os indivíduos, no presente caso, meses ou localidade (EVERITT; DUNN, 1991). A análise de agrupamento (Cluster Analysis) foi realizada com auxílio do software Statística®.

3.6 Tamanho de amostra para o número de anos avaliados

O tamanho de amostra de cada uma das 552 séries temporais (temperatura mínima e máxima) foi determinada para cada uma das 23 estações. Primeiramente, determinou-se a intensidade de amostragem (n_0), considerando uma semi-amplitude do intervalo de confiança (D) igual a $0,5^\circ\text{C}$, com um grau de confiança de 95%, onde $t_{\alpha/2}^2$ é o valor tabelado (Student) a 5% de probabilidade de erro e S^2 é a variância amostral.

Para as variáveis insolação, radiação solar global e radiação fotossinteticamente ativa, em cada uma das 432 séries temporais, determinaram-se o tamanho de amostra para cada uma das 18 estações. Primeiramente, determinou-se a intensidade de amostragem (n_0), considerando uma semi-amplitude do intervalo de confiança (D) igual $0,15\text{h}$, $180\text{cal.cm}^{-2}.\text{min}^{-1}$, $22\text{cal.cm}^{-2}.\text{min}^{-1}$ para as variáveis insolação, radiação solar global e radiação fotossinteticamente ativa, respectivamente, com uma confiança de 95%. Sendo que foram utilizadas as seguintes equações:

$$n_0 = \frac{t_{\alpha/2}^2 S^2}{D^2} \quad (64)$$

Quando o tamanho de amostra calculado for superior a 5% da população amostrada, é necessário calcular o tamanho da amostra para a população finita, obtendo-se, assim, o tamanho final da amostra (n_f) por intermédio da equação:

$$n_f = \frac{n_0}{1 + \frac{n_0 - 1}{Na}} \quad (65)$$

em que **Na** refere-se ao número de anos. Caso n_0 for menor que 5% de **Na**, a aplicação da correção torna-se desprezível, preferindo-se utilizar o tamanho de amostra obtido em n_0 .

3.7 Processos de simulação avaliados

Primeiramente, determinou-se o método de simulação dos dados a ser utilizado para simular os dados de temperatura média do ar e radiação fotossinteticamente ativa. O banco de dados foi formado por 1000 valores simulados das variáveis em cada uma das 24 datas propostas (1º e 16º dias de cada mês do ano). Os dados foram simulados segundo (i) a distribuição normal truncada a mais ou menos 1,96 desvios padrão da média; (ii) distribuição triangular assimétrica; e (iii) distribuição normal bivariada. Nas duas primeiras situações, a simulação dos valores de temperatura e de radiação fotossinteticamente ativa foram realizadas independentemente, desconsiderando a relação de dependência entre as variáveis. Já na terceira situação de simulação, simulou-se, primeiramente, a radiação fotossinteticamente ativa e, a partir dessa, simulou-se a temperatura média do ar (considerando a relação de dependência).

3.7.1 Simulação de dados por intermédio da distribuição normal $\pm 1,96$ desvio padrão da média

A distribuição de probabilidade normal truncada ($\pm 1,96$), com os parâmetros de valor mínimo (**a**), máximo (**b**), média (μ) e variância (σ^2) é apresentada pela equação, segundo Kortum (2002).

$$f(x) = \begin{cases} 0, & \text{se } (x \leq a) \\ \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\} & \text{(se } a < x < b; \mu \in \mathbb{R}, \sigma^2 > 0) \\ 0, & \text{se } (x \geq b) \end{cases} \quad (66)$$

em que $f(x)$ é a função densidade da normal padrão, F a respectiva distribuição acumulada e σ^2 é a variância da normal não truncada correspondente.

A média (μ_s) e a variância (σ_s^2) da distribuição de probabilidade normal truncada simétrica podem ser obtidas por:

$$\mu_s = \left(\frac{a+b}{2}\right) \quad (67)$$

$$\sigma_s^2 = \sigma^2 \left\{ 1 - \left[\frac{bf(b) - af(a)}{F(b) - F(a)} \right] - \left[\frac{f(b) - f(a)}{F(b) - F(a)} \right] \right\} \quad (68)$$

3.7.2 Simulação de dados por intermédio da distribuição triangular assimétrica

A distribuição de probabilidade triangular é utilizada nos casos em que é possível determinar o valor mais provável da variável aleatória, os valores mínimos e máximos, e quando uma função linear parece apropriada para a descrição da distribuição dos valores dos erros das variáveis. Nesses casos, pode-se utilizar a distribuição triangular, que é um bom modelo entre as distribuições normal e uniforme. Segundo Bressan (2002), a área sob a curva da distribuição normal, no intervalo média menos um desvio-padrão até a média mais um desvio-padrão, corresponde a 0,6827. As áreas sob as curvas das distribuições triangular e retangular (ou uniforme) são, respectivamente, 0,64983 e 0,57735, considerando o mesmo intervalo. Essa distribuição de densidade de probabilidade é frequentemente utilizada quando o objetivo é obter uma aproximação na ausência de dados. Então essa permite ajustar uma distribuição mais adequada, ou quando se conhece apenas os valores mais prováveis (m), mínimo (a) e máximo (b) da variável, mas não se conhece muito sobre a distribuição empírica dos dados. A função densidade de probabilidade é dada pela equação:

$$f(x) = \begin{cases} \frac{2(X-a)}{(m-a)(b-a)} & (\text{Se } a \leq X \leq m) \\ \frac{2(b-X)}{(b-m)(b-a)} & (\text{Se } m \leq X \leq b) \\ 0 & (\text{Se } X < a \text{ ou } X > b) \end{cases} \quad (69)$$

3.7.3 Simulação de dados por intermédio da distribuição normal bivariada

Para a realização de dados por intermédio da distribuição normal bivariada, utilizar-se-á os conceitos tratados anteriormente. Primeiramente, devem-se simular duas variáveis aleatórias independentes, com distribuições uniforme no intervalo entre 0 e 1 (κ_1, κ_2). Em seguida, essas variáveis devem ser transformadas para que possuam distribuição normal univariada (BOX; MULLER, 1958).

$$N_1 = \sqrt{-2 \cdot \ln(\kappa_1)} \cdot \cos(2 \cdot \pi \cdot \kappa_2) \quad (70)$$

$$N_2 = \sqrt{-2 \cdot \ln(\kappa_1)} \cdot \sin(2 \cdot \pi \cdot \kappa_2) \quad (71)$$

Sendo N_1 independente de N_2 . Devem-se utilizar as funções seno e co-seno em unidades de radianos.

Para a simulação da radiação fotossinteticamente ativa (Par_i), devem se utilizar a seguinte equação, adaptado de Hogg e Craig, (1978).

$$Par_i = \mu_2 + \sigma_2 \cdot N_1 \quad (72)$$

E para simular os valores de temperatura (T_i) por intermédio da seguinte equação:

$$T_i = (\mu_1 + (\rho \cdot \sigma_1 / \sigma_2) \cdot (Par_i - \mu_2)) + \sqrt{1 - \rho^2} \cdot \sigma_1 \cdot N_2 \quad (73)$$

3.8 Avaliação do processo de simulação bivariada

O processo de simulação bivariada das variáveis temperatura média diária ($^{\circ}\text{C}$) e radiação fotossinteticamente ativa ($\text{cal} \cdot \text{cm}^{-2} \cdot \text{d}^{-1}$) foi avaliado por intermédio da comparação dos parâmetros (média e variância) dos dados originais com os parâmetros das 1000 simulações realizadas.

Para o parâmetro média, realizou-se o teste t, para a hipótese da diferença entre duas médias, com variâncias estimadas. Onde a hipótese nula ($H_0: \mu_1 = \mu_2$) e a hipótese alternativa ($H_1:$

$\mu_1 \neq \mu_2$) foram testadas para cada um dos 366 dias do ano, por intermédio das equações que seguem:

$$t_{cal} = \frac{(\bar{X}_{ob(i)} - \bar{X}_{sim(i)})}{\sqrt{S_m^2}} \quad (74)$$

em que t_{cal} é o valor calculado de t dado por $\bar{X}_{or(i)}$, que é a média observada da variável no dia Juliano i; $\bar{X}_{sim(i)}$ média das 1000 simulações no dia Juliano i; e S_m^2 é a estimativa da variância da diferença entre as estimativas de duas médias, que é calculada por intermédio da seguinte equação:

$$S_m^2 = [(p_{ob} \cdot s_{ob}^2 + p_{sim} \cdot s_{sim}^2) / p] [1/n_{ob} + 1/n_{sim}] \quad (75)$$

Em que n_{ob} é o número de observações da variável observada; n_{sim} é o número de observações da variável simulada (no caso 1000), $p_{ob} = n_{ob}-1$ e $p_{sim} = n_{sim}-1$; $p = p_{ob} + p_{sim}$ e s_{ob}^2 e s_{sim}^2 são as variâncias das variáveis observadas e simuladas, respectivamente. Nesse caso, se $t_{cal} > t_{tab(5\%; p)}$, rejeita-se a hipótese nula em favor da hipótese alternativa, ou seja, as médias obtidas e simuladas no dia Juliano i diferem em nível de 5% de probabilidade de erro pelo teste t.

No caso das variâncias dos parâmetros observados, essas foram avaliadas por intermédio do teste F, onde:

$$F_{cal} = \frac{S_1^2}{S_2^2} \quad (76)$$

em que S_1^2 e S_2^2 são as variâncias obtidas e simuladas, de forma que, como numerador utilizou-se a maior variância, para facilitar a decisão do teste de hipótese. Nesse caso, se $F_{cal} > F_{tab(5\%, g11; g12)}$, rejeita-se a hipótese nula (as variâncias são homogêneas) em favor da hipótese alternativa (variâncias heterocedásticas). Então, deve-se proceder uma modificação na estimativa da estatística t do teste para comparar duas médias e no valor da tabela de t.

Além do teste t e F, utilizou-se a técnica de regressão simples, cuja reta passa pela origem do sistema de eixos coordenados (MORETTI; BUSSAB, 2003). Complementarmente, utilizaram-se indicadores estatísticos como (i) coeficiente de correlação de Pearson (MORETTI; BUSSAB, 2003), o qual é utilizado para mensurar a precisão, a qual indica o grau de dispersão dos dados obtidos em relação a média, ou seja, o erro aleatório; (ii) o índice de concordância de Willmott (Id), dado por uma aproximação matemática que avalia a exatidão, que está relacionada ao afastamento dos valores simulados em relação aos observados (WILLMOTT, 1981), onde a

variação é de zero (nenhuma concordância) até a unidade (concordância perfeita), e o índice de desempenho de Camargo (C), o qual se constitui no produto dos dois índices anteriores (CAMARGO; SENTELHAS, 1997). Com tais procedimentos poder-se-á identificar o grau de precisão e exatidão do processo de modelagem das variáveis (temperatura e radiação fotossinteticamente ativa) e de seus parâmetros (média, desvio padrão, correlação).

$$a = \bar{S} - b\bar{O} \quad (77)$$

$$b = \frac{\sum_{i=1}^{np} O_i S_i - \frac{\sum_{i=1}^{np} O_i \sum_{i=1}^{np} S_i}{np}}{\sum_{i=1}^n O_i^2 - \frac{\left(\sum_{i=1}^{np} O_i\right)^2}{n}} \quad (78)$$

$$\bar{S} = \frac{\sum_{i=1}^{np} S_i}{np} \quad (79)$$

$$\bar{O} = \frac{\sum_{i=1}^{np} O_i}{np} \quad (80)$$

$$r = \frac{np \sum_{i=1}^{np} O_i S_i - \sum_{i=1}^{np} O_i \sum_{i=1}^{np} S_i}{\sqrt{\left[\left(np \cdot \sum_{i=1}^{np} O_i^2 \right) - \left(\sum_{i=1}^{np} O_i \right)^2 \right] \left[\left(np \cdot \sum_{i=1}^{np} S_i^2 \right) - \left(\sum_{i=1}^{np} S_i \right)^2 \right]}} \quad (81)$$

$$Id = 1 - \frac{\sum_{i=1}^{np} (S_i - O_i)^2}{\sum_{i=1}^{np} (|S_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (82) \quad c = r \cdot Id \quad (83)$$

em que **r** se refere ao coeficiente de correlação linear simples de Pearson; **Id** ao índice de concordância de Willmott; S_i ao parâmetro simulado no *i*-ésimo período; O_i ao parâmetro observado no *i*-ésimo período; \bar{O} à média do parâmetro observado na série histórica e **np** ao número de períodos avaliados.

3.9 Descrição do modelo para estimação da produtividade potencial

A duração da fase vegetativa (**DFV**, d) foi estimada conforme modelo apresentado por Rodrigues et al. (2001), com algumas modificações. Foram utilizados os parâmetros obtidos para a variedade cultivada de soja Ocepar 8 (**a** = 0,05327 d⁻¹, **b** = -0,00579 h⁻¹, **c** = 0,001909 D⁻¹.°C⁻¹ e D = 10 d), que possui um período juvenil longo em que o tempo para o florescimento varia entre 54 e 88 dias após a emergência. A duração da fase vegetativa pode assim ser calculada:

$$DFV = \frac{1}{a + b.Nm + c.Tm} + D \quad (84)$$

em que **a**, **b** (d.h⁻¹) e **c** (°C⁻¹) se referem aos parâmetros empíricos do modelo, **Nm** é o fotoperíodo (h.d⁻¹) e **Tm** é à temperatura (°C) média, durante a fase vegetativa.

$$Nm = \frac{\sum_{i=1}^{DFV-10} N_i}{DFV} \quad (85)$$

$$Tm = \frac{\sum_{i=1}^{DFV-10} T_i}{DFV} \quad (86)$$

Assumiu-se duração da fase reprodutiva (**DFR**, d), número de dias do florescimento até o ponto de maturidade fisiológica, constante e igual a 65 dias. Sendo assim, a duração do ciclo (**DC**, d) pode assim ser calculada:

$$DC = DFV + DFR \quad (87)$$

Considerou-se emergência de 300.000 plântulas por hectare. Para efeito de cálculo, utilizou-se o número efetivo de sementes por ha (**Ns** = 300.000 sementes.ha⁻¹). Foi considerado uma massa de 16 g por 100 sementes (**Mcs** = 0,16 g.semente⁻¹), uma proporção do embrião na semente de soja de 15% (**Mes** = 0,15 g.g⁻¹ - 0,15 g de embrião por grama de semente) e uma proporção de folha no embrião de 40% (**Mfe** = 0,40 g.g⁻¹ = 0,40 g de folha por grama de embrião). Portanto, a fitomassa seca inicial de folha (**FSf₀**, kg.ha⁻¹) pode assim ser calculada:

$$FSf_0 = \frac{Ns.Mcs.Mes.Mfe}{1000} \quad (88)$$

A partir dos valores de fitomassa seca de folha viva (**FSf**, kg.ha⁻¹) e da área foliar específica (**Afe**, m².kg⁻¹ = m² de folha por kg de folha seca), a qual, para soja, varia de 15 a 33 m².kg⁻¹ (DRIESSEN; KONIJN, 1992), pode-se calcular o índice de área foliar (**IAF**, m².m⁻²):

$$IAF_i = \frac{FSf_i \cdot Afe_i}{10000} \quad (89)$$

Assumiu-se que a variação temporal (escala diária) da área foliar específica (**Afe**, m².kg⁻¹) em função do desenvolvimento relativo da cultura (**Dr_i**) pode ser caracterizada pelas seguintes equações:

$$Afe_i = Afe_{\max}, \text{ (se } Dr_i = 0) \quad (90)$$


$$Afe_i = Afe_{\min} - (Afe_{\max} - Afe_{\min}) \cdot \ln(Dr_i), \text{ (se } Dr_i > 0) \quad (91)$$

$$Afe_i = Afe_{\max}, \text{ (se } Afe_i > Afe_{\max}) \quad (92)$$

em que **SLA_{max}** e **SLA_{min}** se referem aos limites máximo e mínimo, respectivamente, de área foliar específica (m² kg⁻¹).

A partir das séries históricas das variáveis climáticas citadas anteriormente, serão calculadas as produtividades potenciais da cultura de soja para cada uma das cidades. As produtividades potenciais serão deplecionadas por intermédio do balanço hídrico.

A equação geral correspondente à fotossíntese é assim descrita:



Em função do poder refletor da cultura (**Pr_c** = 0,2 J.J⁻¹) e da interceptação de radiação solar fotossinteticamente ativa (**PAR**, J.m⁻².s⁻¹), calcula-se a radiação solar fotossinteticamente ativa líquida (**PAR_{liq}**, J.m⁻².s⁻¹):

$$PAR_{liq_i} = (1 - Pr_c) \cdot PAR_i \quad (94)$$

Assim, as curvas de resposta da assimilação de dióxido de carbono (**ADC**, kg.ha⁻¹.h⁻¹), correspondente a uma dada concentração de CO₂ na atmosfera (**Co** = 340 vppm), podem ser descritas (GOUDRIAAN, 1982):

$$ADC_i = PLMX_i \cdot \left[1 - e^{-PLEA \cdot \frac{PAR_{liq_i}}{PLMX_i}} \right] \cdot \left(1 + \beta \cdot \ln \left(\frac{Cx}{Co} \right) \right) \quad (95)$$

em que **Cx** se refere à concentração atual de CO₂ na atmosfera (assumiu-se **Cx** = 385 vppm), **PLEA** e **β** aos parâmetros empíricos descritos por Vries et al. (1989) (**PLEA** = 0,48 kg.CO₂.ha⁻¹.h⁻¹.(J.m⁻².s⁻¹)⁻¹ e **β** = 0,8 para espécies C₃ e **β** = 0,4 para espécies C₄) e **PLMX** à variável auxiliar (kg.ha⁻¹.h⁻¹) calculada por intermédio da seguinte expressão:

$$PLMX_i = 40 \cdot \left(\omega_0 + \frac{\omega_1}{\omega_2} \cdot T_i \right) \quad (96)$$

em que T_i se refere à temperatura ($^{\circ}C$) média do i -ésimo dia após a emergência, e ω_0 , ω_1 e ω_2 aos parâmetros empíricos dependentes da temperatura (Tabela 1).

Tabela 1 - Parâmetros empíricos dependentes da temperatura para o cálculo da variável auxiliar $PLMX$ ($kg \cdot ha^{-1} \cdot h^{-1}$)

Condição	ω_0	ω_1	ω_2
Se $T < 0$	0,0	0,0	50
Se $0 \leq T < 20$	0,0	0,3	10
Se $20 \leq T < 30$	-0,2	0,2	5
Se $30 \leq T < 35$	1,0	0,0	5
Se $35 \leq T < 40$	2,4	-0,2	5
Se $40 \leq T < 50$	4,0	-0,4	5
Se $T \geq 50$	0,0	0,0	50

A eficiência inicial da utilização da luz absorvida é caracterizada, em particular, por processos biofísicos sendo os valores constantes. A máxima taxa depende da espécie, refletindo os processos bioquímicos e as condições fisiológicas ideais. A equação referente ao cálculo da assimilação de dióxido de carbono foi estabelecida para condições ótimas de temperatura ($30^{\circ}C$) e na concentração de CO_2 na atmosfera de 340 vppm. Sendo assim, a assimilação de dióxido de carbono máxima, a $30^{\circ}C$, é de $40 \text{ kg} \cdot \text{ha}^{-1} \cdot \text{h}^{-1}$ (BEUERLEIN; PENDLETON, 1971; DORNHOFF; SHIBLES, 1970). A correção para a temperatura é apresentada por Hofstra e Hesketh (1969), sendo que o valor obtido na função anterior deve ser multiplicado pelo valor obtido uma função linear.




Figura 9 - Fator de redução de assimilação de dióxido de carbono para a cultura de soja em função da temperatura do ar (adaptado de HOFSTRA; HESKETH, 1969)

A fotossíntese bruta (FBf_i , $\text{kg} \cdot \text{ha}^{-1} \cdot \text{d}^{-1}$ - quilograma de carboidrato por hectare de folha por dia) é assim calculada:

$$FBf_i = \frac{30}{44} \cdot ADC_i \cdot N_i \cdot f_{_IAF} \cdot f_{_Dr} \quad (97)$$

em que $f_{_IAF}$ e $f_{_Dr}$ se referem, respectivamente, aos fatores de correção referentes ao índice de área foliar e ao desenvolvimento relativo da cultura.

O efeito do auto sombreamento da área foliar passou a ser considerado a partir do valor do fator de índice de área foliar ($f_{_IAF}$) com índice de área foliar (IAF , $\text{m}^2 \cdot \text{m}^{-2}$) superior a $1 \text{ m}^2 \cdot \text{m}^{-2}$ (Figura 10) segundo as seguintes equações:

$$f_{_IAF_i} = 1, IAF_i \leq 1 \quad (98)$$

$$f_{_IAF_i} = e^{\lambda_0 + \lambda_1 \cdot (IAF_i + \lambda_2)} \quad (99)$$

$$f_{_IAF_1} = 0,28 \quad (100)$$

em que λ_0 , λ_1 e λ_2 se referem aos parâmetros ($\lambda_0 = 0,131 \text{ m}^2 \cdot \text{m}^{-2}$, $\lambda_1 = -0,14 \text{ m}^2 \cdot \text{m}^{-2}$ e $\lambda_2 = -0,064284 \text{ m}^2 \cdot \text{m}^{-2}$) empíricos.

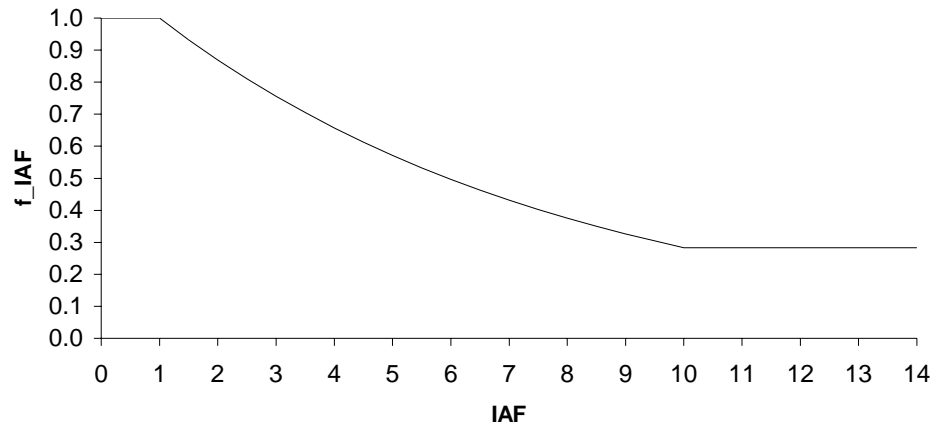


Figura 10 - Relação funcional entre o fator f_{IAF} e o índice de área foliar (IAF, $m^2 \cdot m^{-2}$)

A taxa de fotossíntese decresce com a idade dos tecidos (ou seja, com a idade da planta). Sendo assim, considerou-se que o fator f_{Dr} apresenta a seguinte relação funcional com o desenvolvimento relativo da cultura (Dr) (Figura 11):

$$f_{Dr_i} = 1, \text{ se } Dr_i \leq Dr_{f_{ini}} \quad (101)$$

$$f_{Dr_i} = e^{\frac{\ln(f_{Dr_{fim}})}{f_{Dr_{ini}} - f_{Dr_{fim}}}(Dr_i - Dr_{f_{ini}})} \quad (102)$$

em que $Dr_{f_{ini}}$, $Dr_{f_{fim}}$, $f_{Dr_{ini}}$, e $f_{Dr_{fim}}$ ($Dr_{f_{ini}} = 0,15$, $Dr_{f_{fim}} = 1,00$, $f_{Dr_{ini}} = 1$ e $f_{Dr_{fim}} = 0,45$) se referem aos parâmetros empíricos.




Figura 11 - Relação funcional entre o fator f_{Dr} e o desenvolvimento relativo da cultura (Dr)

A fotossíntese líquida (FLf , $\text{kg}\cdot\text{ha}^{-1}\cdot\text{d}^{-1}$), por unidade de área foliar, num dado dia é calculada pela diferença entre a fotossíntese bruta (FB) desse dia e a respiração de manutenção do dia anterior (RM_{i-1}):

$$FLf_i = FB_i - RM_{i-1} \quad (103)$$

A fotossíntese líquida (FL , $\text{kg}\cdot\text{ha}^{-1}\cdot\text{d}^{-1}$), por unidade de área de solo explorada pela cultura, pode assim ser calculada:

$$FL_i = FLf_i \cdot IAF_i \quad (104)$$

A partir da formação dos fotoassimilados, esses serão alocados aos diferentes órgãos da planta. A fração de alocação dependerá do órgão da planta (raiz, f_{Ri} ; haste, f_{Hi} ; folha f_{Fi} ; ou órgão reprodutivo, f_{ORi} ;) em questão e do desenvolvimento relativo da cultura (Dr_i) (Tabela 2):

$$f_{-R_i} = \frac{\alpha R_0}{\alpha R_1} \cdot (\alpha R_2 \cdot Dr_i + \alpha R_3) + \alpha R_4 \quad (105)$$

$$f_{-H_i} = \frac{\alpha H_0}{\alpha H_1} \cdot (\alpha H_2 \cdot Dr_i + \alpha H_3) + \alpha H_4 \quad (106)$$

$$f_{-F_i} = \frac{\alpha F_0}{\alpha F_1} \cdot (\alpha F_2 \cdot Dr_i + \alpha F_3) + \alpha F_4 \quad (107)$$

$$f_{-OR_i} = \frac{\alpha OR_0}{\alpha OR_1} \cdot (\alpha OR_2 \cdot Dr_i + \alpha OR_3) + \alpha OR_4 \quad (108)$$

Tabela 2 - Parâmetros empíricos, em função do desenvolvimento relativo da cultura de soja, da equação referente ao cálculo da alocação de fotoassimilados à raiz (αR_0 , αR_1 , αR_2 , αR_3 e αR_4), haste (αH_0 , αH_1 , αH_2 , αH_3 e αH_4), folha (αF_0 , αF_1 , αF_2 , αF_3 e αF_4) e órgão reprodutivo (αOR_0 , αOR_1 , αOR_2 , αOR_3 e αOR_4) (adaptado de DRIESSEN; KONIJN, 1992)

Condição	Parâmetros empíricos				
Se $Dr_i \leq 0,24$	$\alpha R_0 = 0,5$	$\alpha R_1 = 0,24$	$\alpha R_2 = -1$	$\alpha R_3 = 0,6$	$\alpha R_4 = 0,0$
	$\alpha H_0 = 0,5$	$\alpha H_1 = 0,24$	$\alpha H_2 = -1$	$\alpha H_3 = 0,6$	$\alpha H_4 = 0,0$
	$\alpha F_0 = 0,4$	$\alpha F_1 = 0,24$	$\alpha F_2 = 1$	$\alpha F_3 = 0,4$	$\alpha F_4 = 0,0$
	$\alpha OR_0 = 0,0$	$\alpha OR_1 = 1,0$	$\alpha OR_2 = 1$	$\alpha OR_3 = 1,0$	$\alpha OR_4 = 0,0$
Se $0,24 < Dr_i \leq 0,40$	$\alpha R_0 = 0,0$	$\alpha R_1 = 1,00$	$\alpha R_2 = 1$	$\alpha R_3 = 1,0$	$\alpha R_4 = 0,1$
	$\alpha H_0 = 0,1$	$\alpha H_1 = 0,16$	$\alpha H_2 = 1$	$\alpha H_3 = -0,24$	$\alpha H_4 = 0,1$
	$\alpha F_0 = 0,1$	$\alpha F_1 = 0,16$	$\alpha F_2 = -1$	$\alpha F_3 = 0,4$	$\alpha F_4 = 0,8$
	$\alpha OR_0 = 0,0$	$\alpha OR_1 = 1,00$	$\alpha OR_2 = 1$	$\alpha OR_3 = 1,0$	$\alpha OR_4 = 0,0$
Se $0,40 < Dr_i \leq 0,48$	$\alpha R_0 = 0,05$	$\alpha R_1 = 0,08$	$\alpha R_2 = -1$	$\alpha R_3 = 0,4$	$\alpha R_4 = 0,1$
	$\alpha H_0 = 0,05$	$\alpha H_1 = 0,08$	$\alpha H_2 = 1$	$\alpha H_3 = -0,4$	$\alpha H_4 = 0,2$
	$\alpha F_0 = 0,1$	$\alpha F_1 = 0,08$	$\alpha F_2 = -1$	$\alpha F_3 = 0,4$	$\alpha F_4 = 0,7$
	$\alpha OR_0 = 0,1$	$\alpha OR_1 = 0,08$	$\alpha OR_2 = 1$	$\alpha OR_3 = -0,4$	$\alpha OR_4 = 0,0$
Se $0,48 < Dr_i \leq 0,61$	$\alpha R_0 = 0,05$	$\alpha R_1 = 0,13$	$\alpha R_2 = -1$	$\alpha R_3 = 0,48$	$\alpha R_4 = 0,05$
	$\alpha H_0 = 0,05$	$\alpha H_1 = 0,13$	$\alpha H_2 = -1$	$\alpha H_3 = 0,48$	$\alpha H_4 = 0,25$
	$\alpha F_0 = 0,1$	$\alpha F_1 = 0,13$	$\alpha F_2 = -1$	$\alpha F_3 = 0,48$	$\alpha F_4 = 0,6$
	$\alpha OR_0 = 0,2$	$\alpha OR_1 = 0,13$	$\alpha OR_2 = 1$	$\alpha OR_3 = -0,48$	$\alpha OR_4 = 0,1$
Se $0,61 < Dr_i \leq 0,90$	$\alpha R_0 = 0,00$	$\alpha R_1 = 1,00$	$\alpha R_2 = 1$	$\alpha R_3 = 1,00$	$\alpha R_4 = 0,00$
	$\alpha H_0 = 0,20$	$\alpha H_1 = 0,29$	$\alpha H_2 = -1$	$\alpha H_3 = 0,61$	$\alpha H_4 = 0,20$
	$\alpha F_0 = 0,5$	$\alpha F_1 = 0,29$	$\alpha F_2 = -1$	$\alpha F_3 = 0,61$	$\alpha F_4 = 0,5$
	$\alpha OR_0 = 0,7$	$\alpha OR_1 = 0,29$	$\alpha OR_2 = 1$	$\alpha OR_3 = -0,61$	$\alpha OR_4 = 0,3$
Se $Dr_i > 0,90$	$\alpha R_0 = 0,00$	$\alpha R_1 = 1,00$	$\alpha R_2 = 1$	$\alpha R_3 = 1,00$	$\alpha R_4 = 0,0$
	$\alpha H_0 = 0,00$	$\alpha H_1 = 1,00$	$\alpha H_2 = 1$	$\alpha H_3 = 1,00$	$\alpha H_4 = 0,0$
	$\alpha F_0 = 0,00$	$\alpha F_1 = 1,00$	$\alpha F_2 = 1$	$\alpha F_3 = 1,00$	$\alpha F_4 = 0,0$
	$\alpha OR_0 = 0,00$	$\alpha OR_1 = 1,00$	$\alpha OR_2 = 1$	$\alpha OR_3 = 1,00$	$\alpha OR_4 = 1,0$

A quantidade de carboidrato alocada à raiz (CHO_{R_i} , kg.ha⁻¹), à folha (CHO_{F_i} , kg.ha⁻¹), à haste (CHO_{H_i} , kg.ha⁻¹) e ao órgão reprodutivo (CHO_{OR_i} , kg.ha⁻¹) é dado por:

$$CHO_{R_i} = FL_i \cdot f_{R_i} \cdot (1 - CRm_{R_i}) \quad (109)$$

$$CHO_{H_i} = FL_i \cdot f_{H_i} \cdot (1 - CRm_{H_i}) \quad (110)$$

$$CHO_{F_i} = FL_i \cdot f_{F_i} \cdot (1 - CRm_{F_i}) \quad (111)$$

$$CHO_{OR_i} = FL_i \cdot f_{OR_i} \cdot (1 - CRm_{OR_i}) \quad (112)$$

em que CRm_{R_i} , CRm_{H_i} , CRm_{F_i} e CRm_{OR_i} se referem aos coeficientes de respiração de manutenção de raiz ($CRm_{R_i} = 0,01$), haste ($CRm_{H_i} = 0,015$), folha ($CRm_{F_i} = 0,015$) e órgão reprodutivo ($CRm_{OR_i} = 0,017$), respectivamente.

A eficiência de conversão de carboidrato para fitomassa seca é dada pela quantidade de carboidrato acumulada multiplicada pela eficiência de conversão. Para o cálculo da fitomassa seca de raiz, haste, folha e órgão reprodutivo, tem-se que:

$$FSr_i = CHO_{R_i} \cdot Ec_{R_i} \quad (113)$$

$$FSh_i = CHO_{H_i} \cdot Ec_{H_i} \quad (114)$$

$$FSf_i = CHO_{F_i} \cdot Ec_{F_i} \quad (115)$$

$$FSor_i = CHO_{OR_i} \cdot Ec_{OR_i} \quad (116)$$

em que Ec_{R_i} , Ec_{H_i} , Ec_{F_i} e Ec_{OR_i} se referem às eficiências de conversão de carboidrato em fitomassa seca de raiz ($Ec_{R_i} = 0,72$), haste ($Ec_{H_i} = 0,69$), folha ($Ec_{F_i} = 0,72$) e órgão reprodutivo ($Ec_{OR_i} = 0,68$), respectivamente.

A partir da fração alocada em cada um dos órgãos da planta, têm-se a quantidade de carboidrato alocada em cada um dos seus órgãos. Essa quantidade de carboidrato deve ser convertida em fitomassa seca. Nesse aspecto, de Vries et al. (1983) apresentam os valores aproximados da conversão de carboidratos em fitomassa seca de grãos para a cultura de soja. A eficiência de conversão varia conforme a composição da fitomassa seca formada (carboidratos, proteínas, lipídios, lignina e ácidos orgânicos) do órgão vegetal (folha, haste, raiz ou órgão reprodutivo). No entanto, o produto primário da fotossíntese é o carboidrato e sua conversão em outros compostos orgânicos envolve um custo energético, representado pela respiração de síntese. Uma aproximação é apresentada por de Vries et al. (1983), onde 1 quilograma de carboidrato fotossintetizado resulta em 404 gramas de proteína, 330 gramas de lipídeos, 472 gramas de

lignina, 826 gramas de carboidrato estrutural e 1104 gramas de ácidos orgânicos. Conhecendo a composição percentual de fitomassa seca da planta de soja³, calcula-se a eficiência de conversão (*Ec*) para cada órgão:

$$Ec = QCE.PCE + QP.PP + QL.PL + QLg.PLg + QAO.PAO \quad (117)$$

em que *QCE* se refere à quantidade de carboidrato estrutural, *PCE* é a composição percentual de carboidrato estrutural na fitomassa seca, *QP* é a quantidade de proteína e *PP* é composição percentual de proteína na fitomassa seca, *QL* é a quantidade de lipídios, *PL* é a composição percentual de lipídios na massa seca, *QLg* é a quantidade de lignina, *PLg* é composição percentual de lignina na massa seca, *QAO* é a quantidade de ácidos orgânicos, e *PAO* é composição percentual de ácidos orgânicos na massa seca.

A fitomassa seca total de folha (*FSTf_i*, kg.ha⁻¹) e de raiz (*FSTr_i*, kg.ha⁻¹) acumulada até o *i*-ésimo dia após a emergência é dada pela seguinte equação:

$$FSTf_i = FSTf_{i-1} + FSf_i - Sf_{i-1} \quad (118)$$

e

$$FSTr_i = FSTr_{i-1} + FSr_i - Sr_{i-1} \quad (119)$$

em que *FSf_i* e *FSr_i* se referem à fitomassa seca de folha e de raiz, respectivamente, produzida no *i*-ésimo dia após a emergência; *FSTf_{i-1}* e *FSTr_{i-1}* à fitomassa seca total de folha e de raiz, respectivamente, acumulada até o (*i-1*)-ésimo dia após a emergência; e *Sf_{i-1}* e *Sr_{i-1}* à senescência de folha e de raiz, respectivamente, ocorrida no (*i-1*)-ésimo dia após a emergência:

$$Sf_i = Fsen.FSf_i \quad (120)$$

e

$$Sr_i = Rsen.FSr_i \quad (121)$$

em que *Fsen* e *Rsen* se referem aos fatores de senescência de folha e de raiz que são função do desenvolvimento relativo da cultura:

$$Fsen_i = 0, \text{ se } Dr_i \leq 0,2 \quad (122)$$

$$Fsen_i = \frac{f_Sen_fim - f_Sen_ini}{Dr_f_Sen_fim - Dr_f_Sen_ini} (Dr_f_Sen_ini + Dr_i), \text{ se } 0,2 < Dr_i \leq 0,65 \quad (123)$$

$$Fsen_i = 1, \text{ se } Dr_i > 0,65 \quad (124)$$

³ Em média, tem-se a seguinte composição da semente botânica de soja: 29% de carboidrato, 37% de proteína, 18% de lipídios, 6% de lignina e 5% de ácidos orgânicos.

e

$$Rsen_i = 0, \text{ se } Dr_i \leq 0,2 \quad (125)$$

$$Rsen_i = \frac{r_Sen_fim - r_Sen_ini}{Dr_r_Sen_fim - Dr_r_Sen_ini} (Dr_r_Sen_ini + Dr_i), \text{ se } 0,2 < Dr_i \leq 0,65 \quad (126)$$

$$Rsen_i = 1, \text{ se } Dr_i > 0,65 \quad (127)$$

em que **Dr_f_Sen_ini**, **f_Sen_ini**, **Dr_f_Sen_fim** e **f_Sen_fim** se referem aos parâmetros empíricos da folha e **Dr_r_Sen_ini**, **r_Sen_ini**, **Dr_r_Sen_fim** e **r_Sen_fim** se referem aos parâmetros empíricos da raiz (**Dr_f_Sen_ini** = **Dr_r_Sen_ini** = 0,2, **f_Sen_ini** = **r_Sen_ini** = 0, **Dr_f_Sen_fim** = **Dr_r_Sen_fim** = 0,65 e **f_Sen_fim** = **r_Sen_fim** = 1). Sendo assim, a senescência das raízes foi calculada de forma análoga à senescência da folha.

A fitomassa seca total de haste (**FSTh_i**, kg.ha⁻¹) e de órgão reprodutivo (**FSTor_i**, kg.ha⁻¹) acumulada até o i-ésimo dia após a emergência é dada pela seguinte equação:

$$FSTh_i = FSTh_{i-1} + FSh_i \quad (128)$$

e

$$FSTor_i = FSTor_{i-1} + FSor_i \quad (129)$$

A respiração de manutenção pode ser quantificada em cada um dos órgãos da planta, tais como: raiz (**RM_r**, kg.ha⁻¹.d⁻¹), haste (**RM_h**, kg.ha⁻¹.d⁻¹), folha (**RM_f**, kg.ha⁻¹.d⁻¹) e órgão reprodutivo (**RM_{or}**, kg.ha⁻¹.d⁻¹). A respiração de manutenção da planta (**RM**, kg.ha⁻¹.d⁻¹) é a soma das respirações de manutenção dos diferentes órgãos vivos, os quais dependem da fitomassa seca e do coeficiente de respiração de manutenção:

$$RMr_i = FSr_i \cdot CRm_r_i \quad (130)$$

$$RMh_i = FSh_i \cdot CRm_h_i \quad (131)$$

$$RMf_i = FSf_i \cdot CRm_f_i \quad (132)$$

$$RMor_i = FSor_i \cdot CRm_or_i \quad (133)$$

$$RM_i = (RMr_i + RMh_i + RMf_i + RMor_i) \cdot m_T \cdot m_Dr \quad (134)$$

em que **CRm_or**, **CRm_f**, **CRm_r** e **CRm_h** se referem aos coeficientes de respiração de manutenção da raiz (**CRm_r** = 0,01 kg.kg⁻¹.d⁻¹ - quilograma de carboidrato - CH₂O - por quilograma de fitomassa seca de raiz - FSr - por dia), da haste (**CRm_h** = 0,015 kg.kg⁻¹.d⁻¹ - quilograma de carboidrato - CH₂O - por quilograma de fitomassa seca de haste - FSh - por dia), da folha (**CRm_f** = 0,015 kg.kg⁻¹.d⁻¹ - quilograma de carboidrato - CH₂O - por quilograma de

fitomassa seca de folha - FSf - por dia) e do órgão reprodutivo ($CRm_{or} = 0,017 \text{ kg.kg}^{-1}.\text{d}^{-1}$ - quilograma de carboidrato - CH_2O - por quilograma de fitomassa seca de órgão reprodutivo - FSor - por dia), respectivamente; e m_T e m_{Dr} se referem aos fatores de temperatura e de desenvolvimento relativo da cultura, respectivamente:

$$m_T = e^{0,0607.T_i - 2,1056} \quad (135)$$

$$m_{Dr} = 1, \text{ se } Dr_i \leq 0,15 \quad (136)$$

$$m_{Dr} = e^{0,21246579 - 1,41643859.Dr_i}, \text{ se } 0,15 < Dr_i \leq 1,00 \quad (137)$$

A fitomassa seca de grãos (FSg, kg.ha^{-1}) é calculada com base na fitomassa seca dos órgãos reprodutivos (FSor, kg.ha^{-1}) (flor, vagem e semente botânica) por intermédio da seguinte expressão:

$$FSg = 0,8.FSTor_{i=DC} \quad (138)$$

Onde 0,8 é a proporção de sementes em relação ao total do órgão reprodutivo. Sendo assim, a produtividade potencial de grãos (PPg , kg.ha^{-1}) pode ser calculada por intermédio da seguinte equação:

$$PPg = \frac{FSg}{1-u} \quad (139)$$

em que u se refere ao teor de água, a base de massa, na semente (considerou-se $u = 0,13 \text{ g.g}^{-1}$ - 13 g de água em 100 gramas de semente úmida).

3.10 Produtividade deplecionada

A produção diária bruta de carboidratos será deplecionada em função da quantidade real de luminosidade (insolação) e por intermédio da quantidade real de água disponível no solo para as plantas.

Primeiramente deve-se simular os dias chuvosos e a quantidade de chuva que ocorre em cada um deles. Deve-se simular um número com distribuição uniforme. Se o número gerado for menor ou igual a probabilidade do dia em questão, então considera-se que o dia seja chuvoso, caso contrário a chuva é igual a zero. Além disso, devem ser considerados os valores mínimos e máximos ocorridos na série histórica do local. A quantidade de chuva calculada para os dias chuvosos é dada através da estimação de dois número aleatórios com distribuição uniforme (U_1 e

U_2), sendo que eles devem ser independentes. Em seguida devem ser estimados os valores V_1 e V_2 .

$$V_1 = 2.(U_1 - 1) \quad (140)$$

$$V_2 = 2.(U_2 - 1) \quad (141)$$

$$VS = V_1^2 + V_2^2 \quad (142)$$

Se o valor simulado (VS) for maior que 1, então deve-se refazer o passo anterior.

Em seguida deve-se calcular o valor acessório (V_x) para o cálculo do valor da chuva simulada (CS) que é dado em função:

$$V_x = V_1 \cdot \sqrt{-2 \cdot \log(VS)/VS} \quad (143)$$

$$CS_i = Cm_i + V_x \cdot C_{dp} \quad (144)$$

Caso os valores da chuva simulada forem maiores ou menor do valor da máximo e mínimo da média histórica para o dia, deve-se recomeçar o processo.

Na literatura (ALLEN et al., 1998; PEREIRA; VILLA NOVA e SEDIYAMA, 1997) são citados alguns métodos para o cálculo da evapotranspiração potencial (Etp, mm.d⁻¹), dentre eles, Thornthwaite (1948), o Tanque Classe A (FAO 56), Penman-Monteith (FAO 56), Hargreaves e Samani (1985), Blaney, Criddle e Makkink (1957). A utilização de determinada metodologia está relacionada a disponibilidade das informações meteorológicas. No presente caso, utilizou-se a metodologia proposta em Thornthwaite (1948) para calcular a evapotranspiração potencial, sendo:

$$ETP_i = 16 \left(10 \frac{T_i}{I} \right)^a \cdot \frac{n_i}{N_i} \cdot \frac{ND_i}{30} \quad (145)$$

em que, I e a são os parâmetros da equação (e serão estimados na seqüência), n é a insolação (h.d⁻¹), N é o comprimento do dia (h.d⁻¹), ND é o número de dias do período em questão e T_m é a temperatura média do i-ésimo período.

$$I = \sum_{m=1}^{12} (0,2 T_m)^{1,514} \quad (146)$$

$$a = 6,75 \times 10^{-7} \cdot I^3 - 7,71 \times 10^{-5} \cdot I^2 + 1,7912 \times 10^{-2} \cdot I + 0,49239 \quad (147)$$

A evapotranspiração da cultura é apresentada por Doorenbos e Kassam (1979), sendo definida como:

$$ETc_i = Kc_i \cdot ETp_i \quad (148)$$

em que, **Kc** é o coeficiente de cultura e **ETp** é a evapotranspiração potencial.

Os valores do coeficiente de cultura são definidos por Doorenbos e Kassam (1979), onde variam em função do desenvolvimento relativo, na seguinte forma: Se $Dr < 0,24$ então $Kc = 0,4$; se o $Dr \geq 0,24$ e $Dr < 0,5$ então $Kc = 0,8$; se $0 \leq 0,5$ e o $Dr < 0,61$ então $Kc = 1,15$; se o $Dr \geq 0,61$ e $Dr < 0,74$ então o $Kc = 0,8$; e se o $Dr \geq 0,74$ então $Kc = 0,5$.

O balanço hídrico normal segue a seqüência apresentada por Thornthwaite e Mather (1955). Deve-se, primeiramente, determinar os valores de negativos acumulados (L_i) e do armazenamento (Arm) (simultaneamente) da seguinte forma: Se a precipitação do dia menos a evapotranspiração potencial forem menor que zero, primeiramente deve ser calculado o negativo acumulado, ou seja, os valores acumulados de precipitação menos evapotranspiração e, posteriormente, calcula-se o valor de armazenamento:

$$Arm_i = CAD \cdot e^{\left| \frac{L_i}{CAD} \right|} \quad (149)$$

em que, **CAD** é a capacidade de água disponível.

Porém, se $(P - Etp) \geq 0$, calcula-se primeiro o ARM [$ARM = ARM \text{ anterior} + (P - Etp)$] e, posteriormente, calcula-se o L_i :

$$L_i = -CAD \cdot \ln\left(\frac{Arm_i}{CAD}\right) \quad (150)$$

Nessa condição, o L_i deve ser determinado caso haja um próximo período com $(P - Etp)$ inferior a 0.

Em seguida, deve-se calcular a alteração no armazenamento, que será o armazenamento atual menos o armazenamento anterior. Com isso, pode-se calcular a evapotranspiração real (Etr):

$$\begin{aligned} Se(P - Etp) < 0 & \quad ETr = P + |Alt| \\ Se(P - Etp) \geq 0 & \quad ETr = Etp \end{aligned} \quad (151)$$

O coeficiente de sensibilidade da cultura a deficiência hídrica, para a cultura de soja, é foi modificada dos valores apresentados Doorenbos e Kassam (1979), e a partir daí pode-se utilizar as relações entre evapotranspiração real e máxima para determinar a produtividade deplecionada (PD , $kg \cdot ha^{-1}$) da cultura, em função da produtividade potencial (PP , $kg \cdot ha^{-1}$).

$$PD = PP \left[1 - Ky_i \left(1 - \left(\frac{ETr_i}{ETc_i} \right) \right) \right] \quad (152)$$

Quando o $Dr \leq 0,24$ então Ky valerá 0,2; quando o Dr estiver entre 0,24 e $\leq 0,4$ o Ky valerá 0,4; quando o Dr estiver entre 0,4 e $\leq 0,8$ o Ky será 0,6; quando o Dr estiver entre 0,48 e $\leq 0,61$ o Ky será 0,8; quando o Dr estiver entre 0,61 e $\leq 0,9$ o Ky será 0,9; e quando o Dr for superior a 0,9 o Ky igual a 1.

3.11 Estimação espacial e confecção de mapas

A interpolação espacial para a confecção de mapas da produtividade potencial e produtividade deplecionada será realizada para o estado de São Paulo, com base na interpolação dos valores obtidos para cada uma das cidades selecionadas. Conceitualmente, interpolação é um procedimento matemático de ajuste de uma função a pontos não amostrados, baseando-se em valores obtidos em pontos amostrados (LANDIM, 2000). Dentre os métodos de interpolação, deve-se considerar as funções globais, que consideram todos os pontos da área, que permite interpolar o valor da função em qualquer ponto dentro do domínio dos dados originais. Para tanto, a adição ou remoção de um valor terá conseqüências no domínio de definição da função. Nesse caso, encontram-se o método dos polinômios e equações multiquádricas. Com relação a funções locais, essas são definidas para porções do mapa, sendo que a alteração de um valor acarretará localmente os pontos próximos ao mesmo. Dentro desse método estão à triangulação, o inverso da potência das distâncias e base radial (krigagem, multiquádrica-biharmônica, splines).

A comparação entre os algoritmos pode ser obtida em (KRAJEWSKI; GIBBS, 1966) e está apresentada na tabela a seguir. O método para estimação do reticulado será a Krigagem, e o software utilizado será o SURFER®. A krigagem trata-se de um processo de estimativa por, média móvel, de valores de variáveis distribuídas no espaço a partir de valores adjacentes, enquanto considerados como interdependentes por uma função denominada de variograma (LANDIM; STURARO, 2002).

Tabela 3 - Aspectos analisados na comparação de algoritmos, fidelidade aos dados originais (FDO), suavidade da curva (SC), velocidade de computação (VC) e precisão geral (PG), considerando 1 como melhor e 5 como pior (KRAJEWSKI; GIBBS, 1966)

Algoritmo	FDO	SC	VC	PG
Triangulação	1	5	1	5
Inverso da Distância	3	4	2	4
Superfície/Tendência	5	1	3	2
Mínima Curvatura	4	2	4	3
Krigagem	2	3	5	1

Os mesmos autores acrescentam que, como no cálculo dessa função a somatória das diferenças ao quadrado é dividida por 2* número de pares de valores, o termo correto seria semi-variograma, porém o emprego do termo variograma, por ser mais sintético. Coletando-se uma variável regionalizada $v(i)$ for coletadas em diversos pontos situados a certa distância h , a influência será tanto maior quanto menor for a distância entre os pontos numa certa direção pode ser expresso pela covariância, sendo os pontos regularmente espaçados por múltiplos inteiros de h . Sendo o vetor h infinitamente pequeno resultará que a variância seja mínima e a covariância seja máxima. Dessa forma, haverá um valor h para o qual ambas podem apresentar valores aproximadamente iguais, porém à medida que h aumenta, a covariância diminui, e aumentando a variância. Isso ocorre porque existe maior independência entre os pontos em distâncias cada vez maiores. A semi-variância distribui-se de 0, quando $h=0$, até um valor mais aproximadamente igual à variância das observações, se os dados forem estacionários, isto é, não ocorrer a presença de deriva. Sendo $v(1), v(2), \dots, v(i) \dots, v(n)$ realizações de uma variável regionalizada, a estimativa não tendenciosa da semi-variância (MATHERON, 1971; LANDIM; STURARO, 2002) é dada por:

$$\gamma(h) = \frac{1}{2n} \sum_{i=1}^{N(h)} (v_{i+h} - v_i)^2 \quad (153)$$

em que $v(x_i)$ é o valor da propriedade medida no local x_i e $N(h)$ o número de pares de dados separados pelo vetor h .

4 RESULTADOS E DISCUSSÃO

A seguir, será apresentada a caracterização dos dados e das estações meteorológicas localizadas no Estado de São Paulo. A série temporal diária para a temperatura do ar, máxima, mínima e média, foi bastante longa para vários locais de São Paulo (Anexo 1). Foram 114 anos em Campinas, 89 em Piracicaba, 62 em Ribeirão Preto e 48 em Jaú e em alguns poucos casos, foram menores que 10 anos (Votuporanga, São Roque e Assis). Outros estudos envolvendo banco de dados de variáveis meteorológicas foram realizados por Cargnelutti Filho, Matzenauer, e Trindade (2004) (série histórica de 36 decênios, para 22 municípios do estado do Rio Grande do Sul), Assis et al. (2004) (86 anos para temperatura do ar e 25 anos para radiação solar) e Catalunha et al. (2002) (utilizaram dados de precipitação decenal e mensal de 243 estações do estado de Minas Gerais, num período de 30 anos). Com isso, espera-se que os resultados deste trabalho sejam bem representativos da variação espacial e temporal no estado de São Paulo.

Considerando a simetria da distribuição normal, a probabilidade de um valor estar acima ou abaixo da média é de 50%. Assim, conhecendo apenas as médias mensais das temperaturas mínima e máxima do ar (Tabela 4 e Tabela 5), pode-se calcular os riscos de ocorrer temperaturas extremas e controlar as melhores épocas dos cultivos agrícolas. Assim, a probabilidade da temperatura mínima do ar, média mensal de janeiro, ser menor ou igual a 21,71°C em Adamantina é de 50%, bem como a probabilidade da temperatura máxima, média mensal de janeiro, em Monte Alegre do Sul, ser inferior ou igual a 28,79°C, também é de 50%. O menor valor de temperatura mínima do ar foi obtido para a média mensal do mês de julho, em todas as 23 estações estudadas.

O conhecimento da temperatura mínima do ar é uma importante ferramenta na determinação da ocorrência de geadas (CAMARGO et al., 1993). Os autores também consideram que em temperaturas inferiores a 2°C, ocorrem prejuízos as culturas. Dessa forma, o mês de julho possui maior probabilidade de ocorrência de geadas, pois possui os valores de temperaturas mínimas diárias mais próximas a temperatura limite inferior da sua ocorrência. Sentelhas, Ortolani e Pezzopane (1995), desenvolveram equações de estimativa da temperatura mínima do ar sobre a relva, e da diferença da temperatura do ar entre a obtida em abrigo e junto à relva. Porém, nem todas as equações mostraram bons resultados quando validadas. A temperatura mínima da relva está correlacionada com a temperatura do ponto de orvalho da noite anterior, temperatura mínima do ar, vento e nebulosidade às 21 horas da noite anterior. Dessa forma, ao

obter valores fidedignos de temperatura mínima do ar para uma dada região, é possível estimar com melhor precisão e exatidão valores como a temperatura mínima sobre a relva.

A temperatura do ar exerce influência nas temperaturas das plantas, animais e até sobre acúmulos de água. Nesse sentido, Angelocci e Villa Nova (1995) avaliaram as variações da temperatura da água de um lago artificial, ao longo de um ano, para a cidade de Piracicaba (SP). Os autores verificaram que as amplitudes térmicas diárias da água nas diferentes profundidades foram bem menores do que as do ar. A temperatura do lago manteve-se, na maior parte do dia, acima da temperatura do ar em dias de alta irradiância, em dias muito nublados ou chuvosos, isso ocorreu nas 24 horas.

Assim, por intermédio de corretas estimações de temperaturas (mínimas e máximas), é possível realizar inferências com maior nível de precisão e exatidão sobre tais variáveis, além de orientar na utilização de outras variáveis associadas, como a disponibilidade de energia solar, umidade do ar e do solo, vento (direção e velocidade), dentre outros.

A temperatura média do ar é o valor médio das temperaturas observadas no intervalo de tempo dado. A média e o desvio padrão mensal estão representados para as diversas localidades do Estado de São Paulo na Tabela 6. Por intermédio desses valores, é possível estimar com um nível de precisão, a probabilidade de uma dada temperatura ocorrer. Certamente, a partir das informações de valores diários, é possível obter melhores estimativas, porém, devido ao volume de dados, optou-se em apresentar somente os valores das médias mensais para todas as variáveis.

Tanto os processos biofísicos quanto os bioquímicos, que condicionam o metabolismo dos seres vivos e, portanto, o seu desenvolvimento, é afetado pelas condições energéticas do ambiente, sendo que as condições de atmosfera e solo são os mais importantes. Dessa forma, o conhecimento do desempenho da temperatura média faz-se importante para a caracterização da adaptabilidade de instalação de uma cultura em uma determinada região. A partir dos valores das variáveis, é possível realizar a construção de tabelas de probabilidades de ocorrência, assim como realizado para as temperaturas médias e máximas pentadiárias (SILVA, LOPARTZ e FERREIRA, 2005; ESTEFANEL, SCHENEIDER e BURIOL, 1994), umidade relativa (SILVA, BURGUEÑO e FERREIRA, 2002), velocidade do vento (SILVA e BURGUEÑO, 2001; SILVA e LARROZA, 1999) e para chuva (ASSIS, 1994).

Na Tabela 7 estão apresentados os valores mensais da média e do desvio padrão para a variável insolação. Por intermédio dos valores diários, foram calculadas as variáveis radiação

solar e radiação fotossinteticamente ativa. Essa variável possui as maiores médias mensais no período de abril a agosto, onde apesar da temperatura ser menor (Tabelas 4, 5 e 6), a precipitação também é reduzida, o que faz com que a quantidade de nuvens seja reduzida, aumentando, assim, o número de horas do brilho solar. Segundo Blanco e Sentelhas (2002), a estimativa de elementos meteorológicos a partir de medições realizadas em estações meteorológicas convencionais e automáticas, é de grande utilidade quando não se dispõe de equipamentos que permitam obter a medição direta da variável desejada. Com isso, os mesmos autores utilizaram medidas da radiação solar global e número efetivo de horas de brilho solar correspondentes a uma série de dados de quatro anos, os quais foram organizados a fim de se obter os coeficientes da ação de Angström-PreScott (*a* e *b*) na escala anual. Além dessa aplicação dos dados, pode-se utilizar, de maneira superficial, porém indicativa do direcionamento da pesquisa. Os dados de temperatura (mínima, máxima e média) insolação e precipitação, podem determinar o risco climático da instalação de determinada cultura, associado a modelos de estimação de produtividades como foi realizado por Rolim, Sentelhas e Húngaro (2001), para a cultura do girassol.

Para a variável radiação solar e radiação fotossinteticamente ativa (Tabela 8 e Tabela 9), verifica-se que o período onde essas variáveis possuem os valores mais elevados são, via de regra, de outubro a março. Isso ocorre devido a região compreendida, dentro da latitude dos locais avaliados, possuírem uma maior exposição solar, aumentando a radiação solar e a radiação fotossinteticamente ativa para essas épocas.

A relação entre a produção de fitomassa com a radiação fotossinteticamente ativa interceptada foi estudada por Schöffele e Volpe (2001) para três cultivares de soja em sete diferentes datas de semeadura. Como resultados os autores verificaram que a eficiência de conversão foi menor no período vegetativo para três cultivares de soja estudadas. Dessa forma, deve-se planejar a instalação da cultura de modo que a maior eficiência de conversão coincida com o período de mais disponibilidade de radiação solar ou radiação fotossinteticamente ativa. Porém, deve-se ter cuidado com as outras variáveis como temperatura e chuva, sendo que essas também são necessárias para o eficaz desenvolvimento da cultura.

No que diz respeito a variável chuva, verifica-se pela Tabela 10, que o local de maior precipitação pluvial é Ubatuba, com precipitações pluviais acima de 300 mm de média mensais, no caso dos meses de janeiro, fevereiro e março. Matzenauer, Cargnelutti Filho e Anjos (2003), determinaram a probabilidade de ocorrer precipitação pluvial igual ou superior a 100% e 60% da

evapotranspiração máxima da cultura (ET_c , $mm.d^{-1}$) de soja, em diferentes subperíodos e épocas de semeadura, para dez localidades do Estado do Rio Grande do Sul (RS). Verificaram que, em 85% e 39% dos casos, a probabilidade de a precipitação pluvial ser igual ou superior à ET_c da cultura de soja e a 60% da ET_c , respectivamente, foi inferior a 0,60, indicando elevada frequência de deficiências hídricas. Durante o subperíodo crítico, a maior probabilidade de a precipitação ser igual ou maior que a ET_c foi de 28%. As menores probabilidades ocorreram durante os subperíodos mais críticos da cultura, compreendidos entre a primeira folha trifoliolada desenvolvida até o início do enchimento de grãos.

Tabela 4 - Estimativa da média e desvio padrão mensal para a temperatura mínima do ar (°C), para as estações meteorológicas localizadas em São Paulo

Mês	Adamantina		Assis		Ataliba Leonel		Campinas		Capão Bonito		Gália		Itararé		Jaú		Jundiaí		Limeira		Mococa			
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$		
Jan	21,71	7,50	19,06	0,24	18,58	1,67	18,58	0,96	18,24	1,52	18,95	0,91	15,46	1,99	19,44	0,67	17,88	1,67	18,35	1,14	19,68	2,97		
Fev	20,96	0,62	19,14	0,56	18,82	0,55	18,79	1,87	18,47	0,51	18,98	0,79	15,74	1,38	19,52	0,57	17,94	2,37	18,45	0,52	19,62	1,97		
Mar	20,34	0,68	18,49	0,45	17,78	0,58	18,07	0,89	17,58	0,66	18,10	1,73	14,99	1,11	18,75	0,74	17,30	1,62	17,55	0,66	18,69	0,44		
Abr	18,33	1,81	16,05	1,07	15,34	2,45	16,02	1,47	15,38	1,52	15,27	2,24	13,31	1,90	16,65	1,30	15,12	3,64	15,34	1,34	16,68	1,26		
Mai	15,30	1,94	12,84	1,23	11,92	2,87	13,40	1,83	12,46	1,71	11,89	2,87	10,67	1,56	13,98	1,58	12,42	4,68	12,79	1,56	14,07	1,69		
Jun	13,87	1,41	11,15	1,10	10,00	1,43	11,79	1,56	10,23	1,67	9,68	2,30	9,03	1,06	12,53	1,41	10,46	2,84	11,42	1,49	12,78	1,71		
Jul	13,18	3,42	10,33	1,79	9,73	2,19	11,27	1,73	9,66	2,75	8,86	4,24	8,67	2,03	12,25	1,89	10,21	2,00	11,03	2,04	12,42	1,80		
Ago	15,44	1,78	12,23	5,66	11,06	1,34	12,48	1,74	10,63	1,74	10,43	4,01	9,53	1,67	13,58	1,15	11,31	1,13	12,29	1,43	13,97	1,09		
Set	16,60	0,96	14,06	1,88	13,23	1,16	14,19	1,41	12,37	1,00	12,74	1,27	10,22	1,07	15,08	0,99	13,27	0,71	13,93	1,40	16,07	1,07		
Out	18,85	1,54	16,13	1,63	15,52	1,05	15,77	1,75	14,90	2,34	15,42	1,39	12,14	1,54	16,65	1,44	14,83	1,06	15,40	1,28	17,59	1,19		
Nov	19,76	1,02	17,08	1,60	16,74	1,52	16,75	1,69	16,10	2,05	16,71	4,65	13,18	2,01	17,64	1,46	15,99	1,51	16,44	1,20	18,65	5,69		
Dez	20,59	0,59	18,10	2,30	18,12	1,06	17,80	1,89	17,39	1,12	18,20	1,45	14,45	1,73	18,81	0,64	17,31	0,55	17,61	1,29	19,13	0,40		
Mês	Monte Alegre do Sul		Nova Odessa		Pariqueraçu		Pindamonhangaba		Pindorama		Piracicaba		Ribeirão Preto		São Roque		Tatuí		Tietê		Ubatuba		Votuporanga	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	18,54	0,37	20,22	0,44	21,27	0,72	19,34	0,92	19,54	0,34	18,98	0,66	18,73	0,60	17,98	1,14	19,24	0,69	19,78	0,52	21,59	0,63	20,98	0,10
Fev	18,62	0,33	20,01	0,37	21,38	0,38	19,30	0,85	19,66	0,31	19,04	0,67	18,71	0,64	17,87	1,01	19,21	0,44	19,76	0,64	21,68	0,49	20,86	0,12
Mar	17,58	0,59	18,96	0,44	20,48	0,44	18,49	0,84	19,00	0,33	18,16	0,75	18,02	0,73	17,41	1,13	18,10	0,47	18,72	0,74	20,94	0,54	20,26	0,30
Abr	15,70	1,09	16,81	1,25	18,59	1,13	16,33	0,84	16,85	1,35	15,37	2,25	15,91	1,74	15,50	3,32	16,01	1,30	16,35	1,04	19,14	0,69	17,96	0,81
Mai	13,12	4,81	14,47	14,23	16,01	2,56	13,20	2,14	14,27	1,42	12,13	2,56	13,43	2,07	12,51	1,25	12,71	1,67	13,09	2,44	16,42	1,31	15,07	1,98
Jun	10,75	1,96	10,86	2,26	13,62	1,55	10,22	2,32	12,85	1,18	10,39	2,04	12,09	1,55	10,02	1,28	10,01	1,46	10,88	1,98	14,19	0,91	13,89	1,29
Jul	10,45	2,47	10,43	3,58	12,92	1,77	10,00	4,11	12,42	1,86	9,58	2,03	11,78	2,24	9,31	2,01	9,31	2,24	10,48	2,75	13,57	1,57	13,22	2,27
Ago	11,55	1,31	11,97	1,59	13,38	1,39	11,03	2,82	13,79	0,88	10,97	1,71	13,56	1,24	10,54	1,58	10,57	1,03	11,78	2,04	14,26	1,11	15,05	0,73
Set	13,82	0,95	14,52	1,10	14,92	0,44	14,03	1,97	15,65	0,82	13,44	1,07	15,50	1,20	12,51	1,05	12,86	0,73	14,10	0,85	15,93	1,15	17,63	0,57
Out	15,62	0,93	16,65	1,08	17,18	0,72	16,63	2,76	17,46	0,75	15,68	1,39	17,06	1,05	14,55	1,60	15,07	1,16	16,44	2,11	17,90	0,81	19,20	0,90
Nov	16,94	3,10	18,24	0,92	18,63	1,14	17,89	2,59	18,30	0,72	16,79	1,46	17,77	1,37	15,59	1,36	17,21	1,67	17,98	0,95	19,64	4,51	19,42	1,40
Dez	17,66	0,34	19,27	0,36	19,91	0,35	18,79	1,04	19,23	0,23	18,20	0,96	18,44	1,12	17,09	0,69	18,11	0,58	19,02	0,46	20,42	0,88	20,62	0,09

Tabela 5 - Estimativa da média e desvio padrão mensal para a temperatura máxima do ar (°C), para as estações meteorológicas localizadas em São Paulo

Mês	Adamantina		Assis		Ataliba Leonel		Campinas		Capão Bonito		Gália		Itararé		Jaú		Jundiaí		Limeira		Mococa			
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$		
Jan	32,56	1,10	30,50	1,46	29,72	1,35	28,84	1,80	28,58	1,64	30,41	0,73	24,56	1,27	29,85	1,42	29,89	1,55	28,89	1,13	29,27	1,42		
Fev	32,16	2,44	30,01	1,12	29,88	1,91	29,02	2,07	28,37	2,22	30,34	1,47	24,45	1,40	29,99	1,91	30,38	2,65	29,20	1,77	29,74	1,70		
Mar	32,05	1,57	30,26	1,16	29,12	4,74	28,74	1,42	27,92	1,13	30,01	1,11	23,69	1,19	29,74	1,18	29,67	1,20	28,81	1,17	29,55	1,13		
Abr	31,24	2,53	29,15	2,37	27,68	1,73	27,17	1,57	26,09	1,36	29,00	1,12	21,93	1,38	28,35	1,45	27,68	1,25	27,37	1,61	28,54	0,77		
Mai	27,97	1,38	25,62	1,32	25,06	1,15	25,05	1,67	23,49	1,30	26,23	0,96	19,40	1,04	25,95	1,15	25,33	1,36	25,06	1,15	26,42	0,91		
Jun	27,26	3,48	24,54	2,89	23,95	2,14	24,05	2,15	22,31	1,92	25,07	1,65	18,37	1,36	25,03	1,63	24,08	1,42	24,10	1,49	25,66	1,10		
Jul	27,62	3,31	24,99	2,84	24,19	2,05	24,36	2,28	23,25	2,58	25,68	2,62	18,64	2,39	25,49	1,89	24,44	1,62	24,53	1,97	26,05	1,53		
Ago	29,55	2,13	27,31	2,10	26,24	2,49	25,97	4,79	24,27	2,44	27,65	2,10	20,09	2,94	27,57	1,94	26,02	1,57	26,59	2,39	28,17	1,75		
Set	29,77	4,15	27,71	4,36	26,83	3,96	26,55	6,42	24,18	3,52	28,07	3,78	20,33	3,39	28,43	4,57	26,50	3,08	27,44	5,50	29,34	4,75		
Out	32,27	4,30	29,56	3,22	28,08	3,23	27,55	4,28	26,00	3,07	29,91	3,59	22,42	2,34	29,39	3,27	27,97	1,70	28,17	2,66	29,60	2,27		
Nov	32,54	1,17	30,17	1,41	29,09	1,45	28,28	1,45	27,13	1,71	30,35	1,03	23,34	1,06	29,59	1,29	28,88	1,54	28,55	1,77	29,42	1,39		
Dez	32,49	1,46	30,45	0,95	29,14	1,32	28,46	1,96	27,70	1,17	30,04	0,81	23,87	1,19	29,44	1,49	29,09	1,25	28,37	1,49	28,95	1,28		
Mês	Monte Alegre do Sul		Nova Odessa		Pariqueraçu		Pindamonhangaba		Pindorama		Piracicaba		Ribeirão Preto		São Roque		Tatuí		Tietê		Ubatuba		Votuporanga	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	28,79	0,85	30,70	2,75	30,89	2,43	32,04	2,97	30,01	1,04	29,96	1,46	29,85	1,32	28,95	1,84	31,31	1,42	30,15	1,40	30,41	2,82	31,25	1,00
Fev	29,15	1,47	30,45	1,86	31,04	1,64	32,69	3,20	30,31	1,49	30,26	1,86	30,20	1,44	28,75	1,60	31,30	2,33	30,30	1,52	30,83	1,11	31,02	1,51
Mar	28,45	0,80	29,98	0,84	29,47	0,67	30,69	4,87	30,02	0,98	30,00	1,21	30,11	1,00	28,34	1,73	30,40	1,10	29,59	0,95	29,48	0,88	30,92	0,66
Abr	27,18	0,43	29,03	3,33	27,70	1,32	29,56	1,05	28,98	0,60	28,38	1,77	29,05	0,89	27,29	3,18	28,66	0,82	28,11	0,65	28,06	1,12	30,18	0,55
Mai	24,90	0,87	26,23	0,94	25,24	1,44	26,96	1,98	26,95	0,74	25,99	2,33	27,07	1,02	24,05	0,43	26,02	1,02	25,67	0,61	26,07	0,91	27,68	0,35
Jun	23,60	1,22	24,85	1,23	23,44	1,34	25,56	1,30	26,20	0,97	25,00	1,82	26,35	1,20	22,61	1,83	24,70	2,34	24,26	1,71	24,99	1,07	27,33	1,17
Jul	23,97	1,46	25,33	2,00	22,90	2,63	25,50	6,79	26,57	1,31	25,27	2,10	26,73	1,55	22,61	2,24	24,82	1,72	24,73	2,01	23,99	1,60	28,12	1,39
Ago	26,03	1,05	27,39	1,42	23,55	1,86	27,46	1,46	28,75	2,10	27,25	2,25	29,18	1,68	24,49	1,80	26,78	1,41	26,37	1,85	24,61	1,38	30,52	1,79
Set	26,66	3,78	27,94	3,55	23,75	2,06	28,07	3,49	29,57	4,11	28,10	3,68	30,27	4,62	24,98	3,52	27,09	3,40	26,84	3,42	24,31	0,97	31,07	4,25
Out	27,87	2,35	29,10	1,94	25,75	1,26	29,78	3,20	30,48	2,34	29,01	2,50	30,46	2,19	26,77	1,94	29,04	2,83	28,73	2,54	25,64	1,10	32,13	3,22
Nov	28,71	1,23	29,98	0,98	28,08	1,45	30,98	3,02	30,28	1,10	29,59	1,69	30,05	1,54	27,67	1,59	30,33	1,92	29,84	1,14	27,36	1,17	31,77	1,32
Dez	28,34	0,82	30,22	5,14	29,71	1,67	31,10	1,35	29,50	2,17	29,64	1,32	29,58	1,16	28,35	0,99	30,63	1,34	29,56	1,37	28,83	0,97	31,34	0,21

Tabela 6 - Estimativa da média e desvio padrão mensal para a temperatura média do ar (°C), para as estações meteorológicas localizadas em São Paulo

Mês	Adamantina		Assis		Ataliba Leonel		Campinas		Capão Bonito		Gália		Itararé		Jaú		Jundiaí		Limeira		Mococa			
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$		
Jan	26,89	2,10	24,78	1,43	25,33	3,01	23,72	1,92	23,41	1,96	24,67	1,54	20,01	1,95	24,65	1,75	23,90	1,78	23,62	1,85	24,48	1,85		
Fev	26,35	1,64	24,57	1,40	25,66	3,38	23,91	1,93	23,42	1,98	24,66	1,56	20,09	1,91	24,75	1,71	24,16	1,89	23,82	1,68	24,68	1,72		
Mar	25,96	1,88	24,37	1,49	24,74	3,40	23,40	1,69	22,75	1,86	24,06	1,65	19,34	1,95	24,25	1,69	23,49	1,68	23,18	1,69	24,12	1,44		
Abr	25,30	2,51	23,71	2,25	24,64	3,37	22,83	2,03	22,10	2,25	23,86	2,14	18,82	2,29	23,70	2,05	22,92	2,23	22,67	2,04	23,83	1,70		
Mai	21,61	2,85	19,22	2,57	19,93	3,86	19,22	2,31	17,97	2,32	19,06	2,38	15,04	2,44	19,96	2,41	18,88	2,35	18,93	2,34	20,25	2,16		
Jun	20,53	3,45	17,83	3,01	18,48	4,02	17,93	2,39	16,27	2,76	17,37	2,77	13,70	2,85	18,78	2,70	17,27	2,48	17,76	2,64	19,22	2,39		
Jul	20,28	3,58	17,65	3,20	18,56	4,43	17,82	2,51	16,46	2,57	17,28	2,90	13,66	3,16	18,87	2,91	17,33	2,56	17,77	2,84	19,24	2,54		
Ago	22,35	3,32	19,74	2,77	20,36	4,58	19,22	2,83	17,45	2,75	19,04	2,82	14,81	3,30	20,57	2,92	18,67	2,61	19,43	3,01	21,08	2,71		
Set	23,15	3,39	20,88	2,95	21,50	4,49	20,36	3,02	18,28	2,94	20,41	2,67	15,32	3,26	21,76	3,15	19,86	2,71	20,68	3,28	22,71	2,88		
Out	25,40	3,13	22,89	2,68	23,19	3,95	21,66	2,85	20,44	2,86	22,66	2,44	17,28	2,80	23,06	2,93	21,40	2,47	21,78	2,72	23,60	2,46		
Nov	25,92	2,58	23,65	2,34	24,26	3,58	22,50	2,33	21,62	2,62	23,53	2,28	18,35	2,97	23,61	2,27	22,44	2,29	22,49	2,36	24,04	2,40		
Dez	26,31	2,13	24,27	1,97	24,80	3,02	23,01	2,49	22,54	2,09	24,12	1,69	19,25	2,47	24,13	1,85	23,20	1,81	22,99	1,98	24,04	1,70		
Mês	Monte Alegre do Sul		Nova Odessa		Pariqueraçu		Pindamonhangaba		Pindorama		Piracicaba		Ribeirão Preto		São Roque		Tatuí		Tietê		Ubatuba		Votuporanga	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	23,66	1,54	25,25	1,56	26,08	2,28	25,69	2,01	24,48	1,95	24,42	1,79	24,29	1,59	23,11	1,65	25,29	1,91	24,93	1,66	26,00	1,15	26,11	1,42
Fev	23,89	1,40	25,23	1,76	26,21	2,18	26,00	1,70	24,70	2,01	24,64	1,98	24,45	1,54	22,91	1,73	25,31	1,90	25,00	1,64	26,31	0,74	25,94	1,34
Mar	23,01	1,48	24,47	1,51	24,98	1,97	24,60	2,07	24,19	2,00	24,15	1,82	24,06	1,45	22,43	2,13	24,28	1,75	24,16	1,58	25,21	0,70	25,59	1,28
Abr	22,45	1,77	24,23	1,94	24,52	2,27	24,86	2,10	23,91	2,52	23,46	2,76	23,75	1,76	20,97	1,89	23,73	2,14	24,01	2,01	23,60	0,87	25,23	2,16
Mai	18,96	2,14	20,35	2,83	20,63	2,50	20,06	2,30	20,15	2,84	18,96	2,85	20,27	2,22	17,87	1,52	19,39	2,24	19,42	2,28	21,25	0,91	21,38	2,31
Jun	17,17	2,40	17,85	2,51	18,53	2,73	17,89	2,46	19,06	2,88	17,56	2,49	19,22	2,26	15,77	2,08	17,24	2,64	17,59	2,58	19,59	0,76	20,61	2,64
Jul	17,20	2,63	17,87	2,84	17,91	3,07	17,75	2,77	19,04	3,29	17,11	2,58	19,28	2,52	15,52	1,77	17,10	2,74	17,54	2,88	18,78	1,03	20,67	2,92
Ago	18,79	2,45	19,68	2,53	18,46	2,97	19,28	2,57	20,75	3,33	18,94	3,13	21,38	2,48	16,98	2,32	18,71	2,60	19,08	2,76	19,44	0,89	22,77	2,55
Set	20,23	2,65	21,23	2,60	19,33	2,68	21,00	2,77	22,13	3,24	20,67	2,76	22,90	2,83	18,23	2,27	19,98	2,77	20,46	2,78	20,12	0,81	24,31	2,54
Out	21,74	2,32	22,87	2,44	21,46	2,65	23,21	2,73	23,57	2,75	22,24	2,54	23,76	2,46	20,25	1,91	22,02	2,65	22,54	2,53	21,77	0,85	25,67	2,38
Nov	22,85	2,25	24,11	2,11	23,36	2,71	24,43	2,45	23,93	2,61	23,34	2,27	23,91	2,02	21,24	1,81	23,83	2,51	23,90	2,22	23,50	1,34	25,55	2,33
Dez	23,00	1,63	24,55	1,67	24,81	2,33	24,94	2,01	23,99	2,19	23,75	1,92	24,02	1,71	22,36	1,48	24,37	1,99	24,20	1,79	24,62	0,89	25,98	1,52

Tabela 7 - Estimativa da média e desvio padrão mensal para a insolação (h.d⁻¹), para as estações meteorológicas localizadas em São Paulo

Mês	Campinas		Capão Bonito		Cravinhos		Gália		Itararé		Jaú		Jundiaí		Limeira		Mococa	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	6,26	1,10	6,04	0,96	6,71	1,56	6,08	1,78	5,52	1,19	6,65	1,02	5,66	0,90	4,38	2,01	6,24	1,13
Fev	6,58	1,49	5,63	1,11	6,51	1,09	5,69	2,05	5,38	1,45	6,78	1,39	6,03	1,54	4,59	2,25	6,43	1,57
Mar	6,92	1,00	6,16	1,36	7,49	0,66	6,08	1,55	5,66	0,95	7,47	0,82	6,70	0,87	4,98	1,95	7,14	1,19
Abr	7,70	0,97	6,94	1,04	8,83	0,79	7,24	1,00	6,19	1,29	8,03	1,00	7,39	0,61	5,53	1,95	7,77	0,80
Mai	7,08	1,50	5,79	0,94	7,47	0,82	6,23	1,48	5,99	1,27	7,62	0,99	6,83	0,44	4,46	1,99	7,38	0,95
Jun	7,09	1,71	5,91	0,73	7,76	0,47	6,36	0,96	6,01	1,08	7,58	1,03	6,69	0,52	4,06	2,35	7,53	0,78
Jul	7,57	1,70	6,25	0,88	8,14	0,44	6,93	1,02	6,34	1,09	8,05	0,78	7,55	0,61	4,89	2,20	7,88	0,71
Ago	7,68	1,48	6,62	1,07	8,32	0,87	6,75	1,58	6,64	0,93	8,19	0,95	8,07	0,90	4,94	2,27	8,01	0,94
Set	6,68	1,25	4,92	0,98	7,60	0,65	5,77	1,62	5,49	1,07	7,14	1,00	6,54	0,92	4,42	1,96	7,22	1,08
Out	6,92	0,96	5,57	1,02	7,90	0,84	6,54	2,20	5,77	1,15	7,25	0,89	6,40	0,59	5,23	2,22	7,13	1,00
Nov	7,17	1,06	6,35	1,29	7,73	1,13	6,91	1,89	6,10	1,14	7,66	1,11	6,97	1,63	5,55	2,00	7,27	0,98
Dez	6,18	1,42	6,31	0,72	6,59	1,25	5,90	1,90	5,45	0,89	6,50	1,27	6,61	0,95	4,19	1,78	6,14	1,41
Mês	Monte Alegre do Sul		Pariqueraçu		Pindamonhangaba		Pindorama		Piracicaba		Ribeirão Preto		Tatuí		Tietê		Ubatuba	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	5,76	1,01	5,09	1,20	5,81	0,86	6,07	1,45	5,98	1,30	6,52	1,22	5,92	1,24	6,85	0,45	4,78	0,95
Fev	5,94	1,24	5,05	1,54	6,09	1,27	6,53	1,86	6,25	1,31	6,58	1,41	5,24	1,13	5,78	1,24	5,68	1,60
Mar	6,46	0,91	4,61	0,82	6,05	0,89	6,68	1,24	6,55	1,06	7,18	0,94	6,03	1,11	6,75	1,14	4,57	1,08
Abr	7,18	0,73	4,88	0,98	6,59	0,90	7,39	0,93	7,08	0,80	7,95	0,87	6,37	2,41	7,89	1,09	5,05	0,67
Mai	6,86	1,51	4,60	1,25	6,21	0,94	6,95	1,32	6,72	1,00	7,40	0,91	6,18	0,72	6,84	0,81	4,88	0,46
Jun	6,98	1,00	4,01	1,09	6,75	0,73	6,84	1,48	6,62	1,00	7,39	0,79	5,96	0,78	6,69	0,48	5,21	0,56
Jul	7,39	0,61	4,47	1,45	6,85	0,76	7,55	1,05	7,17	0,92	7,77	0,65	6,72	0,62	7,12	0,41	4,82	0,81
Ago	7,58	0,82	3,97	0,88	7,22	0,80	7,37	1,19	7,49	0,95	7,83	0,99	7,09	0,98	7,15	0,91	4,85	0,83
Set	6,66	1,13	3,23	1,09	5,82	0,93	6,56	1,42	6,32	1,09	6,96	1,05	6,24	1,04	6,04	1,28	3,41	0,79
Out	6,92	1,04	3,62	1,05	6,15	0,93	7,17	1,67	6,39	1,08	7,35	0,87	6,10	0,69	7,14	0,92	3,74	1,14
Nov	7,14	0,72	4,38	1,32	6,33	0,84	7,26	1,53	6,95	1,21	7,16	0,94	6,96	1,10	7,93	0,92	4,09	0,92
Dez	5,95	1,38	4,73	0,85	5,73	1,49	6,03	1,72	6,12	1,35	6,17	1,35	6,36	1,36	7,19	1,23	4,90	0,97

Tabela 8 - Estimativa da média e desvio padrão mensal para a radiação solar ($\text{cal.cm}^{-2}.\text{d}^{-1}$), para as estações meteorológicas localizadas em São Paulo

Mês	Campinas		Capão Bonito		Cravinhos		Gália		Itararé		Jaú		Jundiaí		Limeira		Mococa	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	518,12	43,68	507,82	38,21	538,43	61,90	501,43	85,59	376,19	35,99	413,93	53,33	387,23	28,32	443,97	79,90	519,40	44,88
Fev	511,66	58,13	471,31	43,21	513,32	42,32	478,65	80,10	393,68	48,26	451,38	47,08	421,36	51,13	435,04	87,88	509,85	61,43
Mar	479,42	36,59	446,80	49,20	508,68	24,56	451,16	56,51	418,98	33,68	494,05	29,54	461,35	31,07	410,47	71,36	494,41	44,14
Abr	440,75	31,58	409,13	32,82	490,28	25,86	420,04	58,12	434,88	46,83	511,19	36,62	483,40	22,39	372,77	63,63	452,59	26,37
Mai	360,61	42,45	316,44	26,34	385,61	23,87	341,07	42,27	411,10	45,35	477,86	35,56	445,66	15,59	288,59	56,76	380,00	27,24
Jun	332,26	45,33	292,97	18,90	365,17	12,08	317,48	25,64	400,41	38,17	463,91	36,60	428,82	18,31	254,27	62,46	355,30	21,21
Jul	361,46	46,72	317,35	24,06	393,33	13,13	348,35	28,48	417,45	38,73	486,22	27,93	464,53	21,88	289,94	61,08	375,94	39,59
Ago	419,57	46,26	379,94	32,80	452,44	27,53	394,48	50,02	442,87	33,59	507,91	34,62	499,50	32,35	336,43	70,96	434,02	49,16
Set	451,53	43,47	384,07	33,90	493,39	23,14	421,75	57,20	408,77	37,75	477,36	36,09	451,36	32,63	373,72	69,34	472,13	54,69
Out	511,20	36,53	456,36	38,84	554,26	32,17	498,23	84,47	406,80	38,44	467,64	30,23	434,29	19,67	447,60	84,91	523,73	38,46
Nov	548,36	41,59	514,18	50,66	573,31	44,75	539,06	74,67	395,14	34,92	456,27	35,07	428,36	51,23	485,11	78,64	554,57	38,85
Dez	518,28	56,31	522,09	28,41	536,04	49,53	507,79	75,43	364,54	26,33	403,48	47,87	405,48	28,42	439,43	70,91	517,76	56,04
	Monte Alegre do Sul		Pariqueraçu		Pindamonhangaba		Pindorama		Piracicaba		Ribeirão Preto		Tatuí		Tietê		Ubatuba	
Jan	498,77	40,22	469,00	47,54	500,13	34,27	512,63	57,74	507,92	51,52	530,54	48,48	504,20	49,08	541,29	17,87	458,59	37,53
Fev	487,17	48,55	446,54	59,48	492,31	49,61	514,05	73,13	500,51	51,06	516,30	55,14	458,03	43,97	479,80	47,94	475,16	62,46
Mar	463,97	33,47	387,25	29,54	448,11	32,67	478,56	45,88	469,13	38,81	497,16	34,83	445,14	40,74	473,27	41,83	392,58	38,26
Abr	425,38	23,80	338,91	30,73	404,41	28,53	441,59	30,83	425,24	26,22	460,26	28,99	395,00	77,06	446,19	35,03	350,73	22,66
Mai	356,65	44,71	278,21	34,51	335,78	26,44	369,37	38,43	355,47	28,54	382,79	26,36	331,96	20,04	352,88	23,01	294,48	12,90
Jun	330,99	26,59	238,98	27,77	322,98	19,35	338,64	40,29	325,00	26,82	353,72	21,70	299,08	20,52	320,77	12,73	278,71	14,66
Jul	357,63	18,37	264,33	39,00	341,24	21,43	373,81	29,75	355,71	25,48	380,28	18,29	335,36	17,63	348,18	11,53	281,99	22,33
Ago	418,12	25,91	293,84	26,93	405,69	24,81	421,22	38,02	418,45	29,88	436,23	31,78	399,00	30,69	403,14	28,36	328,62	25,88
Set	452,22	39,50	321,92	37,91	421,24	32,48	455,99	50,58	442,26	38,55	470,15	37,26	434,49	36,35	428,94	45,47	333,27	27,69
Out	511,70	39,89	379,93	39,81	481,87	35,41	526,17	64,16	493,09	41,39	533,16	33,17	478,15	26,54	519,60	35,21	388,46	43,62
Nov	547,49	28,35	435,70	51,92	515,31	33,39	554,40	60,31	540,84	47,60	550,59	37,15	538,83	43,43	578,26	36,51	426,14	36,38
Dez	509,27	54,95	458,80	33,52	500,46	59,14	513,56	68,14	516,36	53,39	519,30	53,50	525,20	53,67	558,34	48,92	467,02	38,31

Tabela 9 - Estimativa da média e desvio padrão mensal para a radiação fotossinteticamente ativa ($\text{cal.cm}^{-2}.\text{d}^{-1}$), para as estações meteorológicas localizadas em São Paulo

Mês	Campinas		Capão Bonito		Cravinhos		Gália		Itararé		Jaú		Jundiaí		Limeira		Mococa	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	229,99	15,36	226,80	13,86	237,85	21,72	223,24	31,65	169,37	13,18	183,15	19,80	173,51	10,39	203,18	29,60	230,61	15,77
Fev	225,24	20,61	210,79	15,92	226,83	14,27	213,25	29,08	176,84	17,56	198,02	16,62	187,32	18,55	197,80	32,01	224,77	21,40
Mar	208,80	12,77	196,81	17,33	220,21	8,42	198,72	19,71	186,32	12,14	212,83	10,28	201,89	10,71	184,70	25,58	214,29	15,18
Abr	187,74	10,60	176,59	11,49	205,81	8,32	181,38	21,23	189,84	16,49	216,45	12,08	207,21	7,81	165,37	22,65	192,86	8,77
Mai	153,60	14,66	138,07	9,40	164,58	7,96	147,86	14,86	178,72	16,02	201,95	12,08	190,97	5,45	129,94	20,66	161,98	9,16
Jun	141,00	15,90	127,12	6,89	155,25	3,48	137,50	8,93	173,07	13,72	195,71	12,49	183,49	6,75	114,97	23,18	150,99	7,08
Jul	152,66	16,36	136,95	8,26	166,14	4,16	149,82	9,52	179,85	13,45	204,10	9,58	197,02	7,24	129,52	22,30	159,35	14,25
Ago	178,20	16,01	163,94	11,29	191,10	9,16	170,82	17,82	191,16	11,65	214,09	11,64	210,95	10,71	150,61	25,68	184,61	17,68
Set	196,30	15,32	171,51	12,57	212,63	8,05	185,72	20,42	180,55	13,83	205,76	12,75	196,28	11,56	169,17	25,34	204,17	19,98
Out	223,12	12,58	203,42	13,88	238,79	10,50	218,03	30,16	180,76	13,80	202,91	10,51	190,63	7,49	200,76	30,34	227,69	13,35
Nov	239,39	14,40	227,32	17,90	249,03	15,53	235,39	25,95	175,93	12,65	197,70	12,30	187,07	18,45	217,74	28,39	241,64	13,33
Dez	230,15	20,01	231,67	10,36	237,27	17,85	225,83	26,70	164,24	9,83	178,75	17,49	179,07	9,98	202,27	26,31	230,02	19,67
	Monte Alegre do Sul		Pariqueraçu		Pindamonhangaba		Pindorama		Piracicaba		Ribeirão Preto		Tatuí		Tietê		Ubatuba	
Jan	223,60	14,49	212,34	17,82	224,45	12,69	228,33	20,05	226,51	18,44	234,55	17,16	225,22	17,52	238,67	6,09	163,06	10,85
Fev	217,47	17,70	201,78	21,64	219,53	17,72	226,57	25,55	221,60	18,17	227,51	19,31	205,97	15,76	213,62	16,08	182,40	18,97
Mar	203,95	11,74	175,21	10,82	198,33	11,73	209,43	15,51	205,68	13,57	215,60	12,06	197,10	14,16	206,76	14,01	174,53	14,23
Abr	183,71	8,17	151,60	11,45	176,24	9,74	189,77	10,21	183,64	9,05	195,57	9,60	171,58	28,81	189,67	11,47	177,56	9,42
Mai	153,17	13,64	124,49	12,65	146,15	9,22	158,76	12,98	153,39	9,80	163,12	8,93	144,76	7,04	151,89	8,00	167,79	6,16
Jun	141,79	9,53	107,69	10,28	139,11	6,75	145,60	13,76	140,06	9,16	150,69	7,41	130,48	7,51	138,45	4,55	166,40	7,17
Jul	152,64	6,58	117,63	12,99	146,73	7,40	159,16	9,73	152,21	8,50	161,34	6,20	144,79	6,21	149,34	4,13	163,10	10,49
Ago	178,87	8,97	133,17	10,22	173,93	8,57	180,99	12,75	178,99	10,14	185,90	10,77	171,69	10,73	173,39	9,81	170,49	10,88
Set	197,13	14,14	148,74	14,29	185,58	11,51	198,94	17,37	193,70	13,81	203,79	12,97	189,85	13,18	188,15	16,06	155,92	10,36
Out	223,87	13,96	175,32	14,99	213,38	12,98	228,56	21,85	217,11	14,57	231,14	11,32	211,86	9,67	225,67	12,51	157,72	14,26
Nov	239,89	10,03	199,39	19,42	228,84	11,94	241,66	20,40	236,97	16,75	240,31	12,90	236,13	15,45	249,67	12,29	154,89	10,32
Dez	227,30	19,57	208,98	12,71	224,84	21,62	228,91	24,09	229,53	18,96	230,84	18,95	232,98	18,86	244,66	16,87	160,08	10,67

Tabela 10 - Estimativa da média e desvio padrão mensal para chuva (mm) nas estações meteorológicas localizadas em São Paulo

Mês	Campinas		Capão Bonito		Cravinhos		Gália		Itararé		Jaú		Jundiaí		Limeira		Mococa	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	246,34	99,76	205,62	100,58	241,10	142,23	248,89	88,49	229,67	129,75	241,93	91,55	235,79	92,00	244,67	92,72	259,68	90,51
Fev	201,16	89,24	169,51	77,88	286,60	116,96	190,32	78,90	190,25	75,45	203,28	103,09	192,57	78,54	186,22	106,58	202,64	96,84
Mar	151,42	69,76	137,99	66,78	151,94	29,14	154,34	65,33	143,82	67,67	149,30	75,28	154,27	71,13	170,80	108,24	162,44	79,98
Abr	64,07	44,52	70,64	49,70	21,24	16,08	88,18	50,42	82,45	45,65	76,15	47,95	70,94	41,87	77,32	48,01	86,64	55,35
Mai	59,50	47,48	70,98	64,04	57,63	43,23	88,05	67,02	117,87	91,81	68,88	56,91	65,08	55,20	63,87	54,62	65,28	45,52
Jun	57,63	82,73	67,30	57,69	7,70	10,90	62,69	60,24	99,96	78,80	54,11	46,95	55,76	54,67	55,25	51,30	39,43	34,27
Jul	33,92	36,06	57,86	59,67	10,34	14,71	21,53	17,75	71,34	50,51	38,89	42,29	43,50	40,00	35,65	36,01	25,29	30,59
Ago	38,85	33,40	51,16	34,97	47,93	17,14	50,22	47,41	64,49	53,73	40,81	43,23	39,69	38,16	42,10	37,38	36,31	34,57
Set	68,05	52,72	89,76	56,39	62,40	39,54	81,52	55,08	126,15	76,04	72,20	47,29	74,88	65,25	78,24	51,02	70,25	58,26
Out	119,08	62,95	121,07	72,42	72,72	61,19	113,88	79,30	142,81	57,93	117,35	59,02	124,81	56,18	117,13	65,32	135,35	80,31
Nov	149,16	67,87	99,55	60,10	220,34	105,72	131,68	54,49	144,47	64,32	144,91	82,70	143,24	67,70	160,05	67,46	181,56	76,34
Dez	221,60	97,42	157,75	71,71	262,38	80,07	186,37	78,49	215,25	86,41	239,93	82,65	210,90	88,78	222,66	79,02	273,00	101,95
	Monte Alegre do Sul		Pariqueraçu		Pindamonhangaba		Pindorama		Piracicaba		Ribeirão Preto		Tatuí		Tietê		Ubatuba	
Jan	278,73	126,59	227,87	91,24	205,71	61,79	249,23	99,92	228,84	87,35	273,54	106,56	222,31	102,05	232,68	87,50	313,28	135,09
Fev	205,95	99,09	234,98	109,60	193,52	92,14	214,53	103,95	183,57	97,74	222,46	100,21	202,57	89,99	177,56	55,57	325,63	234,74
Mar	193,59	74,81	246,84	105,85	153,07	51,64	157,14	75,95	144,01	78,73	168,30	79,12	167,78	90,93	141,49	78,03	325,29	152,18
Abr	91,52	42,97	97,14	37,10	53,84	30,96	72,65	54,31	63,01	47,19	72,69	56,24	69,63	60,76	71,36	29,84	234,55	135,79
Mai	88,15	66,06	83,28	61,59	52,41	37,30	61,00	51,64	56,68	50,88	55,32	46,26	68,83	53,49	67,64	56,70	127,09	83,35
Jun	58,11	55,70	89,93	60,13	28,49	24,43	40,15	37,20	47,00	40,97	34,36	33,81	42,88	26,61	49,64	43,35	92,88	73,85
Jul	36,87	33,01	70,07	42,92	18,95	16,49	31,45	30,89	30,88	32,69	26,89	30,30	47,08	45,38	28,01	28,54	100,23	76,51
Ago	40,54	37,96	53,91	39,80	27,48	33,33	31,73	32,29	33,74	30,15	29,64	32,25	34,35	18,12	22,43	18,31	70,31	40,31
Set	94,53	68,03	114,84	62,92	75,25	42,89	64,13	48,26	62,72	53,11	56,38	50,72	80,67	47,32	78,95	45,02	193,34	62,78
Out	143,26	88,32	121,53	58,44	125,87	70,00	112,09	58,44	110,74	57,92	126,08	60,69	118,81	55,59	95,60	50,56	218,51	100,01
Nov	147,84	61,56	128,85	68,57	119,15	57,03	136,90	69,57	132,67	62,64	172,15	74,48	106,58	70,32	101,95	61,98	234,14	98,90
Dez	257,86	91,91	162,19	70,12	196,34	76,00	221,82	93,11	200,17	76,42	270,72	115,68	169,12	60,61	151,23	66,77	271,19	144,47

Quanto às distribuições de probabilidade para as variáveis avaliadas, os resultados verificados serão apresentados a seguir.

O percentual dos casos de aderências a cada uma das funções de distribuição de probabilidade testadas, para temperatura, é apresentado pela relação entre o total de números de dias durante o ano (somando para os 23 locais) que aderiram a determinada distribuição de probabilidade e o número máximo possível de séries temporais (23 locais x 366 dias = 8418). Assim, para a temperatura mínima do ar (Tabela 11), as distribuições que apresentaram as melhores aderências foram à distribuição normal (97,66%), a log-normal (93,79%), gama (93,75%) e weibull (89,03%). Ainda, a distribuição exponencial adaptou-se somente em 6% dos dados, devendo ser considerada não apropriada para os estudos de previsão de ocorrências de temperaturas baixas. Também verificou-se que a frequência de aderências manteve-se mais ou menos constante durante todos os meses do ano, na distribuição normal. Porém, para as distribuições log-normal, gama e weibull, houve uma pequena redução nos meses de maio a setembro.

Para a temperatura máxima do ar (Tabela 11), verificou-se que a função de distribuição de probabilidade que melhor se ajustou aos dados é a distribuição log-normal (98,76%), seguida pela normal (98,65), weibull (98,52%), gama (97,85%) e, por último, a distribuição exponencial (1%). A aderência da distribuição log-normal foi superior apenas em 10, das 8418 distribuições avaliadas. Dessa forma, pode-se considerar a distribuição log-normal e a normal como sendo as melhores para descrever o desempenho das séries temporais de temperatura máxima diária. Com isso, a simulação de novos valores pode ser realizada eficientemente por intermédio dessas distribuições.

O conhecimento da função de distribuição de probabilidade mais adequado e as respectivas estimativas dos seus parâmetros (média e desvio padrão), para uma dada variável ambiental e para um dado dia do mês e um local, são importantes para a simulação de situações críticas para um dado cultivo. Estes valores também são importantes para a definição dos modelos matemáticos de crescimento e desenvolvimento de culturas agrícolas. Neste sentido, os resultados obtidos neste estudo são básicos para o desenvolvimento de modelos de crescimento de culturas e simulações de dados meteorológicos.

A partir do conhecimento gerado, a simulação de valores de temperatura mínima e máxima é possível com o uso das estimativas dos parâmetros (média e desvio padrão) da Tabela 4 e

Tabela 5 da função de distribuição normal. Nesse contexto, as variações de produção de uma cultura podem ser calculadas por intermédio das maiores ou menores ocorrências de temperaturas que não correspondem às temperaturas ótimas. Além disso, é possível estimar a duração do tempo (número de dias seguidos) que as temperaturas do ar permanecem acima de determinados valores considerados críticos (ESTEFANEL, BURIOL e SCHNEIDER, 1995). Em modelos de estimação da produção de culturas, existem vias de estimação do rendimento diário que levam em consideração as temperaturas mínimas e máximas. Esses são considerados como fatores de depleção da produtividade, que passará da potencial (potencial genéticos) para a estimação de valores mais próximos a realidade, porque considera o ambiente em que a cultura está inserida, permitindo, assim, um planejamento em nível estadual com menor custo operacional e mais eficiente.

Verificou-se (Tabela 12) que, para a variável temperatura média do ar, os dados dos 18 locais considerados apresentaram um ajustamento de 6503 dias do total de 6588 dias (98,71%), ocorrendo valores semelhantes para as distribuições de probabilidade log-normal (98,59%), gama (96,62%) e weibull (96,96%). Observa-se que a distribuição exponencial teve 100% de aderência na estação localizada no município de Cravinhos, fato devido ao reduzido número de anos que compuseram a série histórica, imprimindo uma característica tendenciosa aos resultados. A respeito desses resultados, há que se considerar que a distribuição exponencial apresentou reduzida aderência (5,72%) para a variável temperatura média do ar. A distribuição exponencial é caracterizada por elevada assimetria dos dados, ou seja, os dados quando plotados possuem uma forma de J invertido.

Para a variável insolação (Tabela 12), verificou-se que as distribuições de probabilidade tiveram uma boa aderência às séries históricas. Nesse caso, novamente, a distribuição normal apresentou o maior número de aderências às séries históricas (5922 dias ou 89,89%), seguida das distribuições gama, log-normal, exponencial e weibull. Uma característica importante é que o número de aderências às distribuições de probabilidade decresce quando comparados os períodos mais secos (inverno) e os períodos mais chuvosos (verão). Essa característica pode ser notada facilmente nas cidades de Campinas, Gália, Jaú, Mococa, Pindorama, Piracicaba e Ribeirão Preto, que possuem séries históricas mais longas, o que torna mais representativa a análise dos dados.

Tabela 11 - Número máximo (Max), mínimo (Min) e médio (Med) de dias do mês dentre os 23 locais observados* e total de dias do ano, que aderiram as funções de distribuições de probabilidade normal (N), exponencial (E), log-normal (LN), gama (G) e weibull (W), pelo teste de Kolmogorov-Smirnov a 5% de probabilidade de erro, para as variáveis temperatura mínima e máxima diária

Temperatura Mínima Diária														
Distr.		Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Total
N	Max	31	29	31	30	31	30	31	31	30	31	30	31	8221
	Min	15	2	3	27	30	28	28	20	21	17	24	24	
	Med	30	27	29	30	31	30	31	30	30	30	30	29	
E	Max	0	1	0	19	25	25	23	19	10	6	1	0	501
	Min	0	0	0	0	0	0	0	0	0	0	0	0	
	Med	0	1	0	1	3	6	7	3	1	0	0	0	
LN	Max	31	29	31	30	31	30	31	31	30	31	30	31	7895
	Min	11	1	3	27	20	17	19	22	23	20	23	20	
	Med	29	27	29	30	30	26	26	28	29	30	29	30	
G	Max	31	28	31	30	31	30	31	31	30	31	30	31	7892
	Min	11	1	6	27	26	21	20	22	24	21	26	21	
	Med	28	24	29	30	30	26	27	29	29	30	30	30	
W	Max	31	28	31	30	31	30	31	31	30	31	30	31	7495
	Min	0	0	0	14	14	15	14	10	3	3	2	2	
	Med	27	24	29	29	29	24	25	28	27	29	27	28	
Temperatura Máxima Diária														
N	Max	31	29	31	30	31	30	31	31	30	31	30	31	8304
	Min	29	26	26	28	28	25	24	18	24	30	29	30	
	Med	31	29	31	30	31	29	30	30	30	31	30	31	
E	Max	2	4	3	6	11	17	17	10	13	4	2	2	126
	Min	0	0	0	0	0	0	0	0	0	0	0	0	
	Med	0	1	0	0	0	1	1	1	1	0	0	0	
LN	Max	31	29	31	30	31	30	31	31	30	31	30	31	8314
	Min	30	25	29	29	28	22	25	13	24	30	29	30	
	Med	31	29	31	30	31	29	30	30	30	31	30	31	
G	Max	31	28	31	30	31	30	31	31	30	31	30	31	8237
	Min	29	25	24	27	28	23	24	13	24	31	29	27	
	Med	31	28	30	30	31	29	30	30	30	31	30	31	
W	Max	31	28	31	30	31	30	31	31	30	31	30	31	8294
	Min	30	27	29	28	29	26	28	26	24	28	28	29	
	Med	31	28	31	30	31	29	30	30	30	31	30	31	

* Adamantina, Assis, Ataliba Leonel, Campinas, Capão Bonito, Gália, Itararé, Jaú, Jundiá, Limeira, Mococa, Monte Alegre do Sul, Nova Odessa, Pariqueraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, São Roque, Tatuí, Tietê, Ubatuba e Votuporanga.

Tabela 12 - Frequência máxima (Max), mínima (Min), média (Med) de dias do mês dentre os 18 locais observados* e total do número de dias do ano que aderiram as distribuições de densidade de probabilidade normal (N), exponencial (E), log-normal (LN), gama (G) e weibull (W), pelo teste de Kolmogorov-Smirnov a 5% de probabilidade de erro, para as variáveis temperatura média do ar e insolação

		Temperatura Média do Ar												
Distr.		Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Total
N	Max	31	29	31	30	31	30	31	31	30	31	30	31	6503
	Min	30	21	22	26	28	25	27	23	28	30	25	24	
	Med	31	28	30	30	31	29	31	30	30	30	31	30	
E	Max	31	29	31	30	31	30	31	31	30	31	30	31	377
	Min	0	0	0	0	0	0	0	0	0	0	0	0	
	Med	2	2	2	2	2	2	2	2	2	2	2	2	
LN	Max	31	29	31	30	31	30	31	31	30	31	30	31	6495
	Min	30	25	26	28	27	24	24	21	29	31	27	15	
	Med	31	29	31	30	31	29	30	30	30	31	30	30	
G	Max	31	29	31	30	31	30	31	31	30	31	30	31	6365
	Min	20	19	13	25	28	24	26	21	29	26	22	16	
	Med	30	27	29	29	31	29	30	30	30	31	29	29	
W	Max	31	29	31	30	31	30	31	31	30	31	30	31	6388
	Min	26	24	27	25	25	25	21	27	18	20	24	8	
	Med	30	28	31	30	30	29	30	30	29	30	29	29	
		Insolação												
N	Max	31	29	31	30	31	30	31	31	30	31	30	31	5922
	Min	31	28	25	11	6	6	6	5	10	22	26	30	
	Med	31	29	30	26	25	24	24	24	26	30	29	31	
E	Max	31	29	31	30	31	30	31	31	30	31	30	31	4771
	Min	8	2	0	0	0	0	0	0	0	0	0	9	
	Med	28	25	22	18	20	19	18	18	22	23	24	28	
LN	Max	31	29	31	30	31	30	31	31	30	31	30	31	5058
	Min	10	3	0	0	0	0	0	0	0	0	0	6	
	Med	29	26	24	21	21	20	20	20	22	24	24	29	
G	Max	31	29	31	30	31	30	31	31	30	31	30	31	5480
	Min	23	17	7	1	0	1	1	0	1	7	8	26	
	Med	30	28	27	23	23	22	22	22	24	27	27	30	
W	Max	31	29	31	30	31	30	31	31	30	31	30	31	4475
	Min	12	6	0	0	0	0	0	0	0	1	0	14	
	Med	28	24	22	17	18	18	17	17	19	21	22	27	

* Campinas, Capão Bonito, Cravinhos, Gália, Itararé, Jaú, Jundiá, Limeira, Mococa, Monte Alegre do Sul, Pariqueraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, Tatuí, Tietê e Ubatuba.

Esses resultados concordam com os obtidos por ASSIS et al. (2004), que para as estimativas diárias da variável temperatura média do ar, verificou que a distribuição normal possui

destaque sobre a distribuição log-normal. Além disso, os mesmos autores indicam que o teste de Kolmogorov-Smirnov pode ser recomendado para verificar o ajuste de uma distribuição estimada a dados observados de temperatura média do ar e radiação solar. Outros resultados importantes foram obtidos por THOM (1966) e SEDIYAMA et al. (1978), reforçando a aceitação da hipótese da normalidade de séries históricas de variáveis climáticas que não possui limite inferior ou superior, tais como conjuntos de dados diários de temperatura e radiação solar global.

Os resultados para a variável radiação solar global (Tabela 13) indicam que a distribuição de probabilidade que melhor se ajustou aos dados foi à distribuição normal (88,18%), seguida pela log-normal (88,05%), gama (87,60), weibull (85,19%) e exponencial (33,99%). Nesse caso, assim como na da insolação, percebe-se um decréscimo de aderências às distribuições em períodos mais secos. Ao analisar-se o número de aderências das distribuições gama, log-normal e normal, verifica-se uma diferença percentual pequena que representa 34 dias de diferença no número de aderências, mas dependendo a interpretação, pode ser determinante na escolha da melhor distribuição de probabilidade.

Para a variável radiação fotossinteticamente ativa (Tabela 13), houve uma inversão do desempenho da percentagem de aderência às distribuições de probabilidade. O maior número de aderências foi obtido na distribuição log-normal (85,70%), seguidos pela distribuição normal (84,38%), gama (84,27%), weibull (81,77%) e exponencial (32,95%). A distribuição exponencial, ao contrário das outras distribuições, comportou-se de maneira alheia, no que diz respeito ao número de aderências, pois, nos períodos de maior radiação solar global e radiação fotossinteticamente ativa (período seco), houve um aumento de aderências. Em contrapartida, para a variável radiação fotossinteticamente ativa, o número de aderências para as outras distribuições de probabilidade reduziram-se de janeiro a junho, e voltaram a aumentar gradualmente de julho a dezembro. Resultados obtidos por Assis et al. (2004) para a variável radiação solar global, para Piracicaba, SP, também indicam que os dados podem ser avaliados segundo a distribuição normal. Trabalhando com 22 séries de dados do município do Rio Grande do Sul, Cargnelutti Filho et al. (2004), verificaram que os dados de radiação solar global (médias decendiais) se ajustam com as funções de distribuição de probabilidade normal, log-normal, gama, gumbel e weibull, apresentando melhores ajustes a distribuição de probabilidade normal.

Tabela 13 - Frequência máxima (Max), mínima (Min), média (Med) de dias do mês dentre os 18 locais observados* e total do número de dias do ano que aderiram as distribuições de densidade de probabilidade normal (N), exponencial (E), log-normal (LN), gama (G) e weibull (W), pelo teste de Kolmogorov-Smirnov a 5% de probabilidade de erro, para as variáveis radiação solar global e radiação fotossinteticamente ativa

Radiação Solar Global														
Distr.		Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Total
N	Max	31	29	31	30	31	30	31	31	30	31	30	31	5809
	Min	31	28	24	10	4	4	3	1	6	19	21	30	
	Med	31	29	30	25	24	23	23	23	23	26	29	29	
E	Max	31	29	31	30	31	30	31	31	30	31	30	31	2635
	Min	0	0	0	0	0	0	0	0	0	0	0	0	
	Med	12	11	12	12	12	13	13	13	13	13	12	11	
LN	Max	31	29	31	30	31	30	31	31	30	31	30	31	5801
	Min	30	28	19	4	2	0	1	0	7	17	19	30	
	Med	31	29	30	25	24	23	22	23	26	29	29	31	
G	Max	31	28	31	30	31	30	31	31	30	31	30	31	5775
	Min	30	26	20	5	2	4	2	1	6	15	20	29	
	Med	31	28	30	25	24	24	23	23	26	29	29	31	
W	Max	31	28	31	30	31	30	31	31	30	31	30	31	5612
	Min	30	27	24	4	1	0	0	0	11	24	23	30	
	Med	31	28	30	23	23	22	20	21	26	30	29	31	
Radiação Fotossinteticamente Ativa														
N	Max	31	29	31	30	31	30	31	31	30	31	30	31	5559
	Min	28	24	16	2	1	0	0	0	4	11	16	27	
	Med	31	28	29	23	23	21	22	22	22	24	28	28	
E	Max	31	29	31	30	31	30	31	31	30	31	30	31	2171
	Min	0	0	0	0	0	0	0	0	0	0	0	0	
	Med	10	10	10	10	10	11	11	11	11	9	9	9	
LN	Max	31	29	31	30	31	30	31	31	30	31	30	31	5646
	Min	29	27	13	1	0	0	0	0	3	13	18	29	
	Med	31	29	29	24	23	22	21	22	25	29	29	31	
G	Max	31	28	31	30	31	30	31	31	30	31	30	31	5552
	Min	28	24	14	2	1	0	1	0	2	10	15	28	
	Med	31	28	28	23	23	22	22	21	24	27	28	31	
W	Max	31	28	31	30	31	30	31	31	30	31	30	31	5387
	Min	30	27	16	2	0	0	0	0	6	14	19	30	
	Med	31	28	29	21	21	20	19	19	24	28	28	31	

* Campinas, Capão Bonito, Cravinhos, Gália, Itararé, Jaú, Jundiá, Limeira, Mococa, Monte Alegre do Sul, Pariqueraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, Tatuí, Tietê e Ubatuba.

Por intermédio dos resultados obtidos, verifica-se que a simulação de dados para a estimativa do clima pode ser realizada, preferencialmente, por intermédio da distribuição normal,

onde esses dados poderão ser utilizados para a simulação de produtividades potenciais ou deplecionados até o planejamento agrícola em escala estadual. Mesmo existindo uma relação de dependência na estimação da radiação solar e radiação fotossinteticamente ativa dos valores de insolação, o número de aderências em cada distribuição de probabilidade é diferente, além da classificação quanto a melhor distribuição de probabilidade. Esse resultado, provavelmente está associado aos erros para a estimação de radiação solar e radiação fotossinteticamente ativa.

A partir dos resultados da Tabela 14, verificou-se que, para a variável chuva, as distribuições de probabilidades que melhor se aderiram aos dados foram a distribuição weibull (94,61%), a log-normal (94,55%), a normal (91,99%), gama (89,99%) e exponencial (77,66%). A intensidade de aderências às distribuições de probabilidade possui uma redução em todas as densidades de probabilidades avaliadas nos meses de junho, julho e agosto. Por intermédio da Tabela 10, verifica-se uma menor precipitação mensal nesses meses, indicando também uma redução no número de ocorrência de precipitações em cada mês. Com essa redução de eventos, existe uma deficiência na representação dos dados desses meses, além da dificuldade de aderência de distribuições de probabilidade aos dados. Existe uma redução gradual no número de aderências às distribuições de probabilidade de janeiro até julho e um gradual aumento de julho a dezembro. Esses resultados possuem outra metodologia de avaliação, comparados com os resultados obtidos por DOURADO NETO et al. (2005), que utilizou o teste de qui-quadrado para os dados de precipitação pluvial diária no município de Piracicaba (SP). Nesse estudo, os autores indicam a distribuição Gama para as estimativas diárias de probabilidade de precipitação pluvial para os meses de janeiro, fevereiro, março, outubro, novembro e dezembro. LYRA, GARCIA e PIEDADE (2006) obtiveram como melhores ajustes das distribuições de probabilidade para valores de precipitação pluvial diária, no estado de Táchira (Venezuela), para os meses secos, como sendo a distribuição exponencial, com exceção da região homogênea, com os maiores valores de precipitação pluvial do período, onde a gama se sobressai. Já no período chuvoso, em todas as regiões homogêneas, a distribuição normal predomina, com exceção de agosto em que, novamente, a gama prevalece. Já nos meses de transição, destacam-se as distribuições gama (abril) e normal (novembro).

A Tabela 10 apresenta as precipitações médias mensais para todos os locais avaliados, juntamente com o seu desvio padrão. Percebe-se que nos meses de junho, julho e agosto, as precipitações ocorrem com menor frequência e com menor intensidade. Isso pode ser verificado

na Figura 13, onde do grupo caracterizado como grupo dos meses secos, nos meses de junho, julho e agosto, essa intensidade é maior, diferenciando-se dos meses de abril setembro e maio. Porém, esses últimos ocorrem antes ou depois do período mais seco, e representam uma preparação (diminuição gradual) da intensidade de precipitação. Em contrapartida, os meses em que ocorrem a maior intensidade de precipitação pluvial são de dezembro e janeiro. E, juntamente com o mês de fevereiro, são classificados, pelo método de Ward, como o grupo de meses chuvosos (Figura 13). Um correto planejamento de cultivos de sequeiro, deve basear-se nessas informações, pois os cultivos devem coincidir o período de maior exigência hídrica com o período de maior disponibilidade do ambiente. Devido às elevadas variações de precipitação, representadas pelo desvio padrão da Tabela 10, existe dificuldade em prever com maiores precisões as datas prováveis de chuva.

Os dados da Figura 10 auxiliam na tomada de decisões, pois apresentam a probabilidade de ocorrência de chuva, que é maior que 60% em alguns dias de janeiro para Campinas, por exemplo. E possuem um mínimo de 10 a 15% de probabilidade de ocorrência em meados de primeiro de julho, para a mesma localidade. Além disso, é possível realizar técnicas de simulação estocástica para a previsão de dados de chuva. A simulação pode ser realizada de 1000 a 10000 vezes. Gera-se um número aleatório com distribuição uniforme (variando de zero a um). Estando o número gerado entre zero e a probabilidade de não ocorrência da chuva, simular-se-á um dia seco. Em caso contrário, se o número gerado estiver entre a probabilidade de não chover e a unidade simular-se-á um dia com chuva, utilizando a distribuição de probabilidade com maior aderência para aquele dia. Essa metodologia foi aplicada por Fonseca e Albuquerque (1978) para a região de Pelotas (RS), sendo que esses autores utilizaram a seguinte equação: $G(X) = P_0 + (1 - P_0)F(X)$, em que P_0 se refere à probabilidade de ocorrência de valores nulos (zeros) de precipitação pluvial diária, $F(X)$ a distribuição cumulativa de probabilidade, que possui o maior número de ajuste para determinado dia do ano. Apesar da metodologia apresentada por esses autores, nesse estudo foi proposta uma metodologia alternativa que será discutido posteriormente.

Tabela 14 - Frequência máxima (Max), mínima (Min), média (Med) de dias do mês dentre os 18 locais observados* e total do número de dias do ano que aderiram as distribuições de densidade de probabilidade normal (N), exponencial (E), log-normal (LN), gama (G) e weibull (W), pelo teste de Kolmogorov-Smirnov a 5% de probabilidade de erro, para a variável chuva

		Chuva												
Distr.		Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Total
N	Max	31	29	31	30	31	30	31	31	30	31	30	31	6060
	Min	10	10	17	22	20	13	10	7	26	25	19	17	
	Med	28	27	29	28	30	27	25	26	29	30	28	29	
E	Max	31	27	29	27	29	27	27	30	30	30	28	31	5116
	Min	21	18	19	17	12	10	8	6	17	22	20	17	
	Med	26	23	25	23	23	21	20	22	25	26	24	27	
LN	Max	31	29	31	30	31	30	31	31	30	31	30	31	6229
	Min	30	27	30	22	20	13	9	7	26	28	28	29	
	Med	31	29	31	28	30	27	24	26	30	31	30	31	
G	Max	31	29	31	30	31	30	30	31	30	31	30	31	5922
	Min	29	25	28	16	14	6	7	5	21	25	23	29	
	Med	31	28	30	26	28	25	22	23	28	30	28	31	
W	Max	31	29	31	30	31	30	31	31	30	31	30	31	6233
	Min	30	27	30	22	20	13	10	7	26	28	28	29	
	Med	31	29	31	28	30	27	25	26	30	31	30	31	

* Adamantina, Campinas, Capão Bonito, Gália, Itararé, Jaú, Jundiá, Limeira, Mococa, Monte Alegre do Sul, Pariqueraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, Tatuí, Tietê e Ubatuba.

A Tabela 15 apresenta os resultados mínimos, máximos e médios para cada localidade, dos parâmetros de forma (α) e de escala (β) para a distribuição gama e weibull. Optou-se em apresentar os valores individualmente, devido às características particulares de cada local, como o tamanho da série histórica. Para fins de comparação, utilizar-se-á os dados de Piracicaba, que obteve como valores mínimos, máximo e médio, 0,44, 3,17 e 0,85, respectivamente, para o parâmetro de forma (α). O parâmetro de escala (β) variou de 1,61, 32,76 e 13,56 (máximo, mínimo e média, respectivamente). Esses dados concordam com Dourado Neto et al. (2005), que estimou esses parâmetros para Piracicaba, porém com outra amplitude da série histórica.

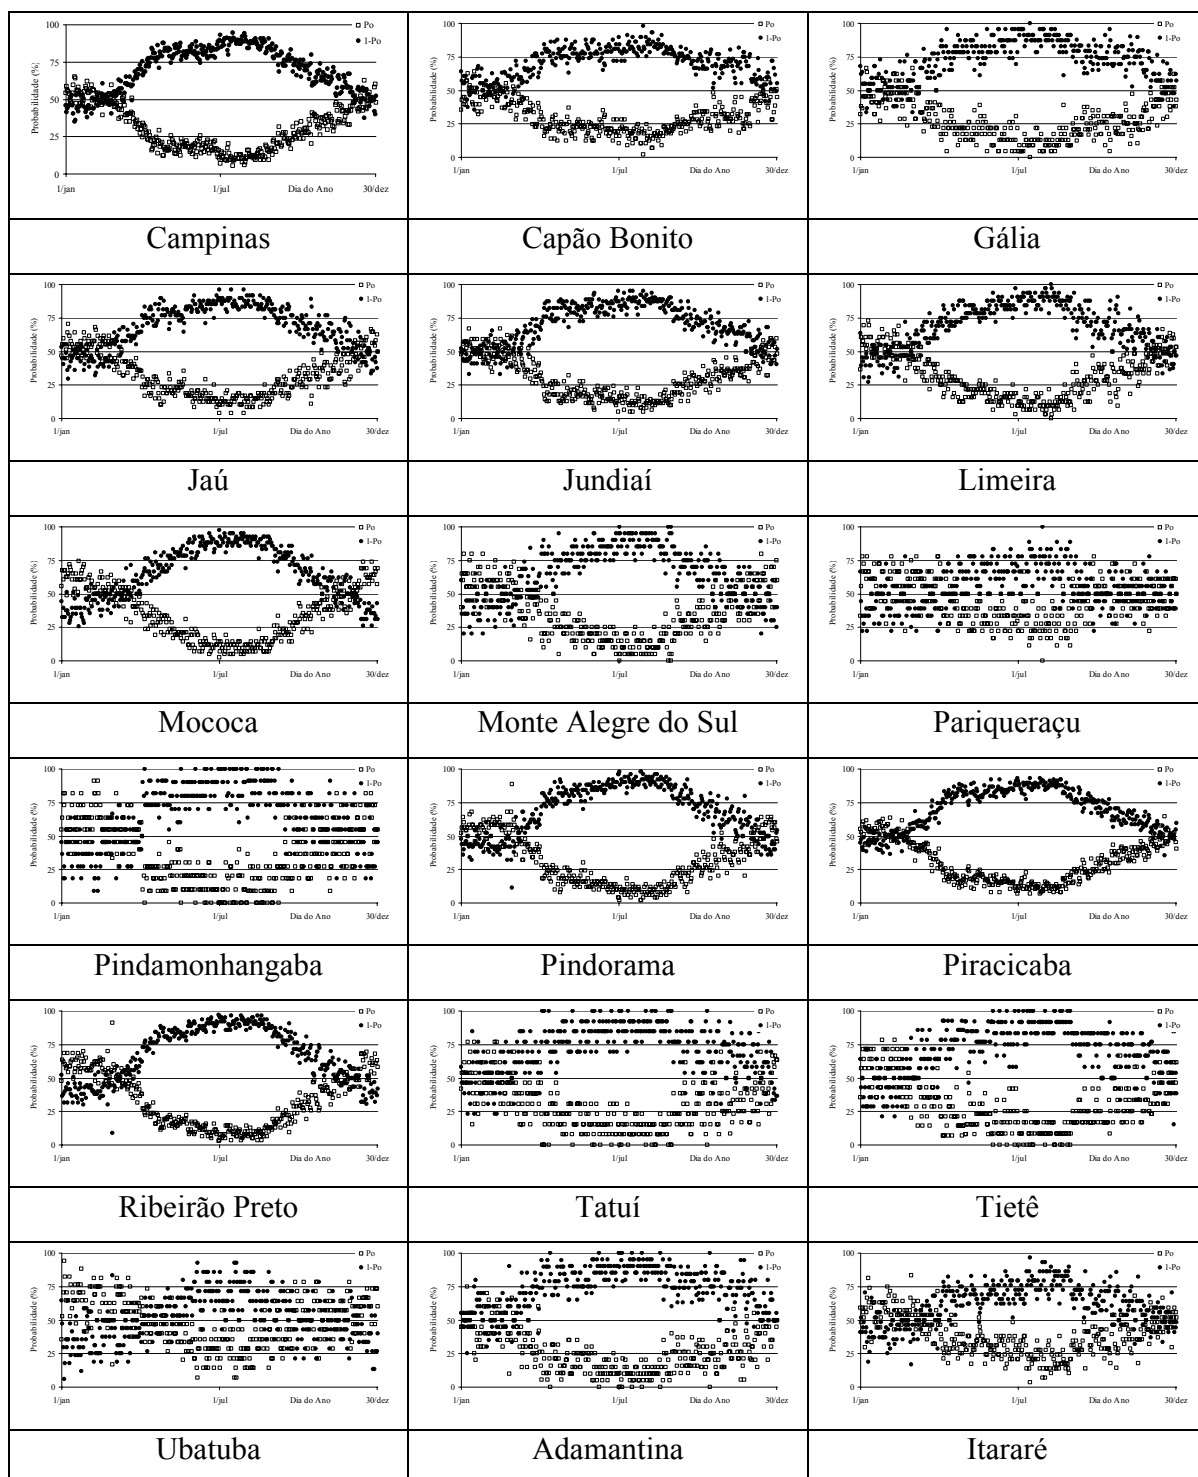


Figura 12 - Probabilidade de ocorrências (P_o) e de não ocorrência ($1-P_o$) de valores de chuva diária em São Paulo

Tabela 15 - Valores mínimos (Min), máximos (Máx) e médios (Med) dos parâmetros alfa e beta das distribuições de probabilidade gama e weibull, para os locais do Estado de São Paulo

	Campinas				Limeira				Piracicaba			
	Gama		Weibull		Gama		Weibull		Gama		Weibull	
	Alfa	Beta	Alfa	Beta	Alfa	Beta	Alfa	Beta	Alfa	Beta	Alfa	Beta
Min	0,49	3,74	2,94	0,52	0,39	0,03	0,77	0,33	0,44	1,61	2,04	0,52
Max	2,33	28,47	26,20	1,36	246,71	72,73	36,64	94,87	3,17	32,76	22,15	1,64
Med	0,82	14,63	10,59	0,81	2,03	12,71	11,98	1,17	0,85	13,56	9,83	0,80
	Capão Bonito				Mococa				Ribeirão Preto			
Min	0,47	2,69	3,52	0,46	0,29	0,01	1,07	0,30	0,31	0,41	1,12	0,32
Max	2,47	47,78	26,07	1,63	386,44	57,70	28,11	12,51	20,52	57,95	45,37	3,41
Med	0,92	13,64	11,00	0,83	2,94	14,58	10,07	0,80	0,99	14,80	10,41	0,78
	Gália				Monte Alegre do Sul				Tatuí			
Min	0,32	0,09	1,25	0,30	0,37	0,02	1,12	0,24	0,43	0,03	0,46	0,36
Max	65,97	55,42	35,84	50,30	217,44	55,77	45,73	26,52	85,65	67,82	48,36	113,97
Med	2,28	11,06	14,30	1,17	2,37	13,34	12,43	0,95	3,80	10,00	13,71	1,59
	Itararé				Pariqueraçu				Tietê			
Min	0,34	0,16	0,57	0,34	0,38	0,02	0,59	0,41	0,36	0,01	0,43	0,28
Max	16,80	62,69	39,94	3,50	28,95	53,49	42,66	3,73	653,56	52,34	42,55	32,04
Med	0,91	15,49	10,53	0,74	1,13	12,19	9,15	0,80	6,66	10,00	11,22	1,39
	Jaú				Pindamonhangaba				Ubatuba			
Min	0,39	0,10	2,33	0,41	0,35	0,00	0,28	0,25	0,32	0,03	0,36	0,24
Max	48,92	39,32	24,98	5,59	600,47	62,40	34,38	17,39	54,67	172,46	41,43	4,69
Med	1,03	14,92	10,50	0,77	8,30	10,42	9,74	1,10	1,43	19,96	11,59	0,76
	Jundiaí				Pindorama				Adamantina			
Min	0,43	1,39	3,75	0,44	0,39	0,42	1,50	0,29	0,37	0,04	1,19	0,28
Max	4,64	35,25	26,86	1,97	14,75	62,82	34,95	2,42	120,67	93,76	49,28	50,30
Med	0,95	13,84	11,56	0,84	0,94	14,44	10,71	0,76	2,87	13,54	14,81	1,41

Além disso, Botelho e Morais (1999), estimando os parâmetros da distribuição gama, coletadas em 30 anos, concluem que o parâmetro de forma de modo geral, é menor nos meses chuvosos (junho, julho e agosto) e maior nos meses mais chuvosos (novembro, dezembro e janeiro), e aumenta de valor a medida que o tamanho do período aumenta. Com relação às estimativas dos parâmetros de escala, foram menores nos períodos de 1-3 e 1-6 nos meses mais secos (junho, julho e agosto), indicando que nos outros meses não houve uma tendência definida quanto ao aumento dos períodos, e os maiores valores ocorreram nos meses chuvosos.

Para a distribuição weibull, os valores de posição (α) variaram de 2,04, 22,15 e 9,83, para mínimo, máximo e média, respectivamente (Piracicaba). Já os parâmetros de escala (β), variaram de 0,52, 1,52 e 0,80 para mínimo, máximo e média, respectivamente. Esses dados concordam com Dourado Neto et al. (2005).

A Tabela 16 apresenta os valores originais de média, desvio padrão, covariância e correlação para as variáveis radiação fotossinteticamente ativa e temperatura média do ar (média para 17 locais), nas 24 datas durante o ano. Esses resultados serão comparados com os resultados obtidos para a simulação dos dados por intermédio dos três métodos de simulação propostos. Apesar dos valores de correlação apresentados na Tabela 16 variarem de -0,16 a 0,58, ao analisarmos os valores durante o ano em cada cidade (e não na média) verificou-se que a correlação pode variar de -0,30 a 0,75. São esses valores de correlação que são importantes como um dos parâmetros para a simulação de dados por intermédio da distribuição normal bivariada. Então se verifica que na natureza (dados observados) existe uma correlação entre as duas variáveis, que é positiva durante os meses quentes e negativa durante os meses de inverno, que se caracterizam por ser um período seco, ou seja, com menor incidência de nuvens e por isso maior radiação fotossinteticamente ativa disponível e a temperatura mais baixa devido a inclinação da terra em relação ao eixo vertical.

Os parâmetros simulados por intermédio da distribuição triangular assimétrica são apresentados na Tabela 17. E, por intermédio desses dados verificamos que apesar de na natureza existir uma relação de dependência entre a radiação fotossinteticamente ativa e a temperatura, nessa modalidade de simulação os resultados de correlação entre as duas variáveis apresentou correlação bem próxima a nulidade em todos os casos. Isso ocorre certamente devido ao processo de simulação de uma variável ocorrer independentemente do da outra.

Tabela 16 - Parâmetros originais média (\hat{m}), desvio padrão ($\hat{\sigma}$), covariância (COV) e correlação entre a radiação fotossinteticamente ativa e temperatura média (ρ) para as variáveis radiação fotossinteticamente ativa (PAR) e temperatura média do ar (TEMP), nas 24 datas, para os 17 locais* do Estado de São Paulo

Datas	PAR		TEMP		COV	ρ
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$		
1/jan	215,99	55,71	24,16	2,05	37,59	0,37
16/jan	219,51	54,65	24,55	2,08	34,81	0,40
1/fev	212,95	48,19	24,63	2,13	37,66	0,49
16/fev	213,54	51,53	24,41	1,79	40,43	0,58
1/mar	200,52	48,92	24,15	1,82	31,87	0,38
16/mar	206,90	41,05	23,46	1,90	6,75	0,12
1/abr	187,85	40,66	23,24	1,77	19,22	0,28
16/abr	181,53	38,39	22,05	2,61	1,16	0,05
1/mai	176,39	32,83	20,10	2,61	6,86	0,11
16/mai	149,66	37,19	19,28	2,46	9,14	0,12
1/jun	148,75	33,30	17,22	2,99	-11,94	-0,13
16/jun	145,82	28,29	17,57	2,45	13,35	0,21
1/jul	149,99	24,83	18,11	2,41	1,67	-0,04
16/jul	152,88	30,94	17,63	3,03	-1,64	-0,06
1/ago	170,85	27,60	18,13	3,08	20,83	0,35
16/ago	182,70	31,07	19,23	3,21	-11,99	-0,16
1/set	183,77	39,78	20,38	3,00	27,18	0,30
16/set	191,49	42,40	20,22	2,96	5,78	0,02
1/out	198,59	49,54	20,99	2,39	9,48	0,08
16/out	203,99	56,96	22,40	2,84	10,96	0,02
1/nov	216,64	51,69	22,63	2,99	10,43	0,06
16/nov	239,69	50,81	23,16	2,65	17,59	0,19
1/dez	220,10	57,36	23,39	2,10	43,46	0,47
16/dez	222,78	53,35	23,88	2,07	21,48	0,27

*Campinas, Cravinhos, Capão Bonito, Gália, Itararé, Jaú, Jundiaí, Limeira, Mococa, Monte Alegre do Sul, Pariqueraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, Tatuí e Tietê.

Tabela 17 - Parâmetros média (\hat{m}), desvio padrão ($\hat{\sigma}$), covariância (COV) e correlação entre a radiação fotossinteticamente ativa e temperatura média (ρ) para as variáveis radiação fotossinteticamente ativa (PAR), temperatura média do ar (TEMP), diferença absoluta dos valores das médias dos parâmetros em relação aos valores originais (DIF), para a simulação triangular assimétrica, nas 24 datas, para os 17 locais do Estado de São Paulo

Datas	PAR				TEMP				COV	DIF	ρ	DIF
	\hat{m}	DIF	$\hat{\sigma}$	DIF	\hat{m}	DIF	$\hat{\sigma}$	DIF				
1/jan	216,61	0,63	32,65	23,06	23,32	0,84	1,75	0,30	0,85	36,73	0,01	0,36
16/jan	218,47	1,04	31,68	22,97	24,44	0,11	1,73	0,35	0,10	34,71	0,00	0,40
1/fev	209,50	3,45	29,74	18,45	24,38	0,25	1,69	0,44	-0,08	37,74	0,00	0,49
16/fev	210,21	3,33	31,13	20,40	24,24	0,17	1,40	0,39	-0,24	40,67	0,00	0,58
1/mar	199,51	1,01	28,82	20,10	23,70	0,44	1,48	0,34	0,21	31,66	0,00	0,37
16/mar	199,55	7,35	26,74	14,31	23,46	0,01	1,36	0,53	0,25	6,50	0,00	0,11
1/abr	181,80	6,05	26,09	14,57	22,92	0,32	1,31	0,46	-0,25	19,47	-0,01	0,29
16/abr	174,28	7,25	24,51	13,88	21,22	0,83	1,95	0,65	-0,01	1,17	0,00	0,05
1/mai	167,69	8,70	22,50	10,33	19,73	0,37	2,13	0,48	0,68	6,18	0,02	0,10
16/mai	146,03	3,63	22,38	14,82	18,89	0,38	1,82	0,64	0,36	8,77	0,01	0,11
1/jun	140,91	7,83	21,28	12,02	16,51	0,72	2,34	0,65	-0,48	11,46	-0,01	0,12
16/jun	139,89	5,94	18,40	9,89	17,39	0,18	1,77	0,69	0,00	13,35	0,00	0,21
1/jul	142,47	7,51	17,30	7,54	17,25	0,85	2,12	0,30	0,20	1,47	0,00	0,04
16/jul	145,88	7,01	20,34	10,60	17,51	0,12	2,30	0,73	-0,25	1,39	0,00	0,07
1/ago	159,55	11,30	20,25	7,35	16,96	1,17	2,60	0,47	0,42	20,41	0,00	0,35
16/ago	170,53	12,17	23,03	8,04	18,42	0,81	2,60	0,61	0,45	12,44	0,00	0,16
1/set	179,47	4,30	24,89	14,89	20,13	0,25	2,26	0,74	-0,64	27,83	0,00	0,29
16/set	187,81	3,68	26,42	15,98	19,84	0,39	2,26	0,69	-0,48	6,26	0,00	0,02
1/out	196,33	2,26	29,02	20,52	20,91	0,08	1,97	0,41	-0,59	10,07	0,00	0,07
16/out	201,97	2,02	31,93	25,03	22,44	0,04	2,08	0,76	-0,26	11,22	0,00	0,01
1/nov	211,86	4,78	31,96	19,73	22,43	0,20	2,18	0,81	-0,22	10,65	0,00	0,05
16/nov	230,47	9,23	32,40	18,41	22,91	0,25	2,15	0,50	-1,01	18,61	0,00	0,18
1/dez	218,95	1,15	32,92	24,44	23,12	0,26	1,61	0,49	-0,43	43,89	0,00	0,46
16/dez	219,54	3,24	32,92	20,42	23,24	0,63	1,65	0,42	0,34	21,14	0,00	0,26
Soma		124,85		387,74		9,67		12,86		433,79		5,17

Tabela 18 - Parâmetros média (\hat{m}), desvio padrão ($\hat{\sigma}$), covariância (COV) e correlação entre a radiação fotossinteticamente ativa e temperatura média (ρ) para as variáveis radiação fotossinteticamente ativa (PAR), temperatura média do ar (TEMP), diferença absoluta dos valores das médias dos parâmetros em relação aos valores originais (DIF), para a simulação normal truncada a 1,96 desvio padrão da média, nas 24 datas, para os 17 locais do Estado de São Paulo

Datas	PAR				TEMP				COV	DIF	ρ	DIF
	\hat{m}	DIF	$\hat{\sigma}$	DIF	\hat{m}	DIF	$\hat{\sigma}$	DIF				
1/jan	216,25	0,26	48,57	7,14	23,97	0,19	1,64	0,42	0,30	37,29	0,00	0,37
16/jan	218,59	0,92	47,80	6,85	24,50	0,05	1,70	0,38	-0,13	34,94	0,00	0,40
1/fev	213,05	0,10	41,92	6,27	24,62	0,01	1,68	0,44	0,26	37,40	0,00	0,48
16/fev	213,83	0,29	45,24	6,29	24,48	0,07	1,41	0,38	-0,61	41,04	-0,01	0,59
1/mar	200,32	0,20	42,33	6,59	24,17	0,03	1,43	0,39	-0,04	31,91	0,00	0,38
16/mar	206,35	0,55	35,88	5,16	23,78	0,32	1,52	0,38	-0,11	6,86	0,00	0,12
1/abr	187,52	0,33	35,20	5,46	23,26	0,02	1,38	0,38	0,08	19,14	0,00	0,27
16/abr	181,83	0,30	33,69	4,70	22,02	0,02	2,13	0,48	-0,10	1,26	0,00	0,05
1/mai	176,42	0,04	28,68	4,15	20,40	0,30	2,16	0,45	1,15	5,71	0,02	0,10
16/mai	149,17	0,49	32,48	4,71	19,24	0,03	2,06	0,40	-0,19	9,32	0,00	0,12
1/jun	149,06	0,32	29,07	4,23	17,32	0,10	2,60	0,39	-0,64	11,30	-0,01	0,13
16/jun	145,93	0,11	24,70	3,59	17,54	0,03	2,09	0,36	0,40	12,95	0,01	0,20
1/jul	150,07	0,08	21,63	3,20	18,11	0,01	2,05	0,37	0,53	1,14	0,02	0,06
16/jul	153,07	0,19	26,71	4,24	17,86	0,23	2,60	0,43	0,25	1,89	0,01	0,07
1/ago	170,75	0,10	24,25	3,35	18,00	0,13	2,62	0,46	0,28	20,55	0,01	0,34
16/ago	182,69	0,01	27,13	3,94	19,01	0,23	2,75	0,45	0,28	12,27	0,00	0,16
1/set	183,64	0,12	34,61	5,17	20,52	0,14	2,55	0,45	-0,38	27,57	-0,01	0,30
16/set	191,94	0,45	36,80	5,60	20,31	0,09	2,52	0,44	-0,42	6,20	0,00	0,02
1/out	198,80	0,21	43,10	6,44	21,11	0,12	1,98	0,41	-0,76	10,24	-0,01	0,09
16/out	203,91	0,08	49,76	7,20	22,50	0,10	2,38	0,46	0,79	10,17	0,00	0,01
1/nov	216,41	0,23	45,16	6,53	22,78	0,15	2,48	0,51	-0,05	10,48	0,00	0,06
16/nov	239,33	0,37	44,52	6,29	23,09	0,07	2,19	0,46	-1,18	18,78	-0,01	0,19
1/dez	219,78	0,32	49,73	7,63	23,38	0,01	1,71	0,39	0,26	43,20	0,00	0,46
16/dez	222,63	0,16	46,01	7,34	23,79	0,09	1,68	0,39	-0,11	21,60	0,00	0,27
Soma		6,24		132,08		2,52		10,06		433,19		5,25

* Campinas, Cravinhos, Capão Bonito, Gália, Itararé, Jaú, Jundiá, Limeira, Mococa, Monte Alegre do Sul, Pariqueraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, Tatuí e Tietê.

Para a simulação normal truncada a 1,96 desvio padrão da média (Tabela 18) também se verifica que a simulação dos dados não proporciona uma correlação da radiação fotossinteticamente ativa com a temperatura do ar. Esse fato também pode ser atribuído aos valores simulados serem realizados separadamente (independentes).

A simulação dos dados por intermédio da distribuição normal bivariada está representada na Tabela 19. Nesse caso, verificamos a relação de dependência que está expressa pelos valores de

correlação. Apesar dos valores simulados de radiação fotossinteticamente ativa e temperatura simulada por intermédio das distribuições triangular assimétrica e normal truncada a 1,96 desvio padrão da média, serem bastante próximos dos valores originais, a simulação normal bivariada proporcionou valores mais fidedignos aos originais. Esse fato pode ser observado por intermédio do somatório absoluto das diferenças entre os valores originais e os valores simulados, que em praticamente em todas as situações comportou-se de maneira inferior, ou bastante similar, quando comparados com a simulação triangular assimétrica e normal truncada. Além disso, a situação apresentada por intermédio da simulação normal bivariada faz com que os valores sejam o mais próximos aos valores originais devido a correlação que existe entre as duas variáveis.

Por intermédio dos resultados das Tabelas 20, 21 e 22, é verificado o desempenho das variáveis simuladas por intermédio da correlação entre os valores observados da radiação fotossinteticamente ativa e os valores simulados da mesma radiação fotossinteticamente ativa para o determinado dia Juliano. E da mesma forma para a temperatura média do ar. Além disso, são apresentados os índice de concordância de Willmott, coeficiente angular da reta e índice de desempenho de Camargo, para as três situações de simulação.

Realizando uma análise em conjunto das Tabelas 19, 20 e 21, verifica-se que a correlação dos dados originais e os simulados é muito boa nas simulações normal truncada e normal bivariada, em contrapartida a simulação triangular deixa a desejar, assim como o índice de concordância de Willmott, coeficiente angular da reta e índice de desempenho de Camargo. A escolha de determinado método de simulação dos dados deve levar em consideração o maior número de testes estatísticos possíveis para assim realizar uma escolha levando em consideração um maior número de critérios possíveis.

Tabela 19 - Parâmetros média (\hat{m}), desvio padrão ($\hat{\sigma}$), covariância (COV) e correlação entre a radiação fotossinteticamente ativa e temperatura média (ρ) para as variáveis radiação fotossinteticamente ativa (PAR), temperatura média do ar (TEMP), diferença absoluta dos valores das médias dos parâmetros em relação aos valores originais (DIF), para a simulação normal bivariada, nas 24 datas, para os 17 locais do Estado de São Paulo

Datas	PAR				TEMP				COV	DIF	ρ	DIF
	\hat{m}	DIF	$\hat{\sigma}$	DIF	\hat{m}	DIF	$\hat{\sigma}$	DIF				
1/jan	215,88	0,11	55,49	0,23	23,93	0,22	1,86	0,19	33,59	4,00	0,33	0,04
16/jan	220,33	0,82	54,24	0,41	24,47	0,08	1,93	0,15	37,84	3,03	0,38	0,02
1/fev	212,54	0,41	48,47	0,28	24,60	0,03	1,96	0,17	40,50	2,84	0,45	0,04
16/fev	213,34	0,20	51,27	0,26	24,47	0,06	1,63	0,16	46,55	6,12	0,54	0,04
1/mar	200,12	0,41	48,82	0,11	24,20	0,05	1,65	0,17	33,93	2,06	0,38	0,00
16/mar	206,81	0,09	41,29	0,24	23,79	0,33	1,76	0,14	7,38	0,63	0,13	0,02
1/abr	188,05	0,19	40,44	0,22	23,28	0,05	1,58	0,18	23,31	4,09	0,31	0,03
16/abr	181,28	0,26	38,32	0,07	22,02	0,02	2,46	0,14	-1,78	2,94	0,02	0,03
1/mai	176,49	0,10	32,75	0,08	20,37	0,27	2,47	0,14	7,80	0,94	0,12	0,01
16/mai	149,71	0,05	37,01	0,18	19,24	0,04	2,36	0,10	10,97	1,84	0,12	0,00
1/jun	148,76	0,02	33,42	0,12	17,35	0,12	3,00	0,01	-18,70	6,76	-0,14	0,01
16/jun	145,57	0,25	28,39	0,10	17,59	0,01	2,40	0,06	16,62	3,27	0,24	0,02
1/jul	150,09	0,10	24,92	0,09	18,13	0,02	2,38	0,04	5,19	3,52	0,01	0,05
16/jul	153,19	0,31	31,14	0,19	17,79	0,16	2,93	0,10	-3,21	1,57	-0,06	0,00
1/ago	171,09	0,23	27,58	0,02	18,00	0,13	2,93	0,14	19,24	1,59	0,32	0,03
16/ago	182,58	0,13	30,88	0,19	19,04	0,20	3,16	0,05	-13,07	1,09	-0,16	0,00
1/set	183,65	0,11	39,89	0,11	20,48	0,10	2,90	0,10	33,71	6,52	0,30	0,00
16/set	191,65	0,16	42,24	0,16	20,30	0,08	2,88	0,08	4,53	1,25	0,02	0,01
1/out	198,91	0,32	49,60	0,06	21,12	0,13	2,25	0,13	9,81	0,33	0,08	0,00
16/out	204,72	0,72	57,14	0,18	22,49	0,09	2,73	0,11	-1,16	12,12	0,02	0,00
1/nov	216,78	0,14	50,72	0,97	22,79	0,16	2,86	0,14	1,94	8,49	0,04	0,02
16/nov	239,59	0,10	50,59	0,21	23,11	0,05	2,54	0,12	20,16	2,57	0,16	0,02
1/dez	219,32	0,78	57,34	0,02	23,38	0,01	1,97	0,14	55,97	12,51	0,45	0,01
16/dez	223,59	0,80	52,91	0,44	23,80	0,07	1,92	0,15	31,04	9,56	0,25	0,02
Soma		6,81		4,95		2,51		2,87		99,64		0,42

* Campinas, Cravinhos, Capão Bonito, Gália, Itararé, Jaú, Jundiá, Limeira, Mococa, Monte Alegre do Sul, Pariqueraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, Tatuí e Tietê.

Em Dourado Neto et al. (2005) foram considerados dois casos para caracterizar a distribuição temporal (valores diários), das séries históricas de temperatura média e de radiação solar global. No primeiro caso, utilizou-se a distribuição normal truncada a $\pm 1,96$ desvios padrão da média, com a temperatura média variável e a radiação solar global diária constante. No segundo caso, utilizou-se a mesma distribuição, porém a radiação solar global era variável e a temperatura média do ar era constante. Os autores utilizaram o índice de concordância de Willmott, o coeficiente angular da reta e o índice de desempenho de Camargo, para 24 diferentes

datas de semeadura (1º e 15º dias de cada mês), para avaliar as simulações. Porém, nessa situação também não aplicou-se o testes de Bartlett, F e t, entre os valores observados e simulados, tão pouco verificou-se a distribuição de probabilidades correspondentes aos dados observados e simulados. E apesar das conclusões expressarem que as simulações apresentam elevados índices de exatidão e precisão, dever-se-iam efetuar mais testes para avaliar melhor os processos de simulação. Mesmo assim, por intermédio da metodologia empregada, verificou-se que as estimativas de produtividades potenciais geradas (ASSIS et al. 2006), representam a produtividade potencial para a cultura do milho em Piracicaba, SP.

Dessa forma, levando em consideração os testes estatísticos utilizados, verifica-se a superioridade na simulação dos dados de radiação fotossinteticamente ativa e temperatura média do ar por intermédio da simulação normal bivariada.

Além da similaridade entre os valores observados e os simulados, deve-se observar outros parâmetros para poder usar uma determinada simulação com maior convicção sobre como melhor fazer a simulação de dados. O teste de homogeneidade de variância, entre as variâncias observadas de um determinado dia e as variâncias simuladas desse dia foram testadas pelo teste de homogeneidade de variâncias de Bartlett e teste F (Tabela 23). A partir dos resultados da Tabela 23, verifica-se as rejeições para o teste de homogeneidade de Bartlett e teste F. Apesar dos valores simulados por intermédio da distribuição triangular assimétrica e normal truncada, para as duas variáveis, serem aparentemente semelhantes, verifica-se as variâncias entre os dados observados e simulados são heterogêneas, indicando assim que houve uma alteração no conjunto de dados simulados que implica na mudança da amplitude da variância.

Tabela 20 - Coeficiente de correlação entre os valores observados e simulados da mesma variável (ρ), índice de concordância de Willmott (ID), coeficiente angular da reta (b) e índice de desempenho de Camargo (c), para a radiação fotossinteticamente ativa (PAR) e temperatura média do ar (TEMP), para a simulação triangular assimétrica, nos 17 locais do Estado de São Paulo

PAR				TEMP			
ρ	ID	b	C	ρ	ID	B	C
0,82	0,98	1,00	0,99	0,64	0,96	0,98	0,94
0,85	0,98	0,98	0,97	0,57	0,96	0,99	0,96
0,80	0,98	1,00	0,98	0,61	0,96	0,98	0,95
0,85	0,98	0,98	0,96	0,68	0,96	0,99	0,95
0,78	0,99	0,97	0,96	0,56	0,95	0,86	0,82
0,86	0,99	0,97	0,96	0,67	0,98	0,98	0,97
0,84	0,99	0,95	0,94	0,68	0,99	0,98	0,97
0,82	0,99	0,95	0,94	0,65	0,99	0,97	0,96
0,88	0,99	0,96	0,95	0,53	0,99	0,99	0,98
0,79	0,99	0,96	0,95	0,66	0,99	0,97	0,96
0,78	0,99	0,96	0,95	0,64	0,99	0,97	0,96
0,79	0,99	0,96	0,94	0,46	0,99	0,96	0,95
0,81	0,99	0,95	0,94	0,76	0,99	0,96	0,95
0,88	0,99	0,95	0,94	0,52	0,99	0,96	0,95
0,80	0,99	0,95	0,94	0,69	0,99	0,96	0,95
0,79	0,99	0,95	0,94	0,58	0,99	0,96	0,96
0,82	0,99	0,98	0,97	0,57	0,99	0,98	0,97
0,77	0,99	0,98	0,97	0,52	0,99	0,99	0,98
0,86	0,98	0,98	0,96	0,53	0,99	0,99	0,98
0,90	0,98	0,99	0,97	0,57	0,98	0,99	0,98
0,86	0,98	0,99	0,97	0,60	0,98	1,00	0,98
0,88	0,99	0,97	0,96	0,60	0,98	0,98	0,96
0,83	0,98	1,00	0,98	0,56	0,98	0,98	0,95
0,86	0,99	1,00	0,98	0,44	0,97	0,84	0,81

* Campinas, Cravinhos, Capão Bonito, Gália, Itararé, Jaú, Jundiá, Limeira, Mococa, Monte Alegre do Sul, Pariqueraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, Tatuí e Tietê.

Tabela 21 - Coeficiente de correlação entre os valores observados e simulados da mesma variável (ρ), índice de concordância de Willmott (ID), coeficiente angular da reta (b) e índice de desempenho de Camargo (c), para a radiação fotossinteticamente ativa (PAR) e temperatura média do ar (TEMP), para a simulação normal truncada a 1,96 desvio padrão da média, nos 17 locais do Estado de São Paulo

PAR				TEMP			
ρ	ID	b	c	ρ	ID	B	c
0,98	0,99	1,00	0,99	0,99	0,99	0,99	0,98
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,96	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,96	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	0,99	0,98
0,99	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,99	0,99	1,00	0,99	0,99	0,99	1,00	0,99
0,99	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,99	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	0,97	0,96
0,98	0,99	1,00	0,99	0,96	0,99	1,00	0,99
0,99	0,99	1,00	0,99	0,99	0,99	1,00	0,99
0,99	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,99	0,99	1,00	0,99
0,98	0,99	0,99	0,98	0,99	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,99	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99

* Campinas, Cravinhos, Capão Bonito, Gália, Itararé, Jaú, Jundiaí, Limeira, Mococa, Monte Alegre do Sul, Pariqueraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, Tatuí e Tietê.

Tabela 22 - Coeficiente de correlação entre os valores observados e simulados da mesma variável (ρ), índice de concordância de Willmott (ID), coeficiente angular da reta (b) e índice de desempenho de Camargo (c), para a radiação fotossinteticamente ativa (PAR) e temperatura média do ar (TEMP), para a simulação normal bivariada, nos 17 locais do Estado de São Paulo

PAR				TEMP			
ρ	ID	b	c	ρ	ID	B	c
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,96	0,99	1,00	0,99
0,97	0,99	1,00	0,99	0,93	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,88	0,94	1,00	0,96
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,99	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,99	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,99	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,95	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,99	0,99	1,00	0,99
0,99	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,98	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99
0,98	0,99	1,00	0,99	0,97	0,99	1,00	0,99

* Campinas, Cravinhos, Capão Bonito, Gália, Itararé, Jaú, Jundiá, Limeira, Mococa, Monte Alegre do Sul, Pariqueraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, Tatuí e Tietê.

Somando-se a isso, verifica-se pelo teste t (comparação das médias observadas e simuladas para um determinado dia Juliano) que em 33% dos 6222 testes realizados (17 cidades x 366 dias do ano) houve rejeição no que diz respeito a média dos valores observados e os simulados (distribuição triangular assimétrica e normal truncada), para a variável radiação fotossinteticamente ativa. E um pouco superior a isso para a variável temperatura. Em contrapartida a simulação realizada pela distribuição normal bivariada indicou que os dados simulados, para ambas as variáveis não rejeitam o teste de homogeneidade de variâncias de

Bartlett e teste F. E no que diz respeito à comparação das médias dos valores observados e simulados, verificou-se que apenas em um caso, dos 6222 avaliados, para a temperatura média do ar houve diferenças estatísticas, podendo ser considerado esse valor desprezível.

Assis et al. (2006) utilizaram a distribuição triangular para simular os valores de radiação solar e temperatura média diária, sendo esses utilizados no modelo para o cálculo da produtividade potencial. A avaliação do processo de simulação também se utilizou do índice de concordância de Willmott, coeficiente angular da reta e índice de desempenho de Camargo, para 24 diferentes datas de semeadura (1º e 15º dias de cada mês). Porém, não se aplicou o testes de Bartlett, F e t, entre os valores observados e simulados, tão pouco verificou-se a distribuição de probabilidades correspondentes aos dados observados e simulados. Nesse estudo os valores do coeficiente de determinação variaram de 0,5 a 0,95 para as duas variáveis aproximadamente. O índice de concordância de Willmott, apresentou valores de variação semelhantes e o coeficiente angular da regressão simples apresentou valores superiores a 0,94. Ao considerarem-se somente os valores apresentados por esses testes de avaliação, para um tipo de simulação, não faz-se difícil dar confiabilidade a determinado tipo de simulação de dados. Porém, no caso da simulação de processos presentes na natureza que são correlacionados, deve-se comparar mais métodos de simulação, além de aplicar um maior número de testes para a melhor decisão. Certamente, a simulação triangular se adapta aos casos em que é possível determinar o valor mais provável da variável aleatória, o seu valor mínimo e máximo e quando uma função linear parece apropriada para a descrição da distribuição dos valores dos erros das variáveis.

Tabela 23 - Número de rejeições para o teste de Bartlett, teste t e teste F, entre os valores observados e valores simulados (triangular assimétrica, normal truncada a 1,96 desvio padrão da média e normal bivariada), nos 17 locais nos 366 dias do ano (6222 testes), para a radiação fotossinteticamente ativa (PAR) e temperatura média do ar (T)

Simulação	PAR			T		
	Bartlett	F	T	Bartlett	F	T
Triangular	5636	5902	2052	2370	3144	2104
Normal truncada	64	335	0	307	834	0
Normal Bivariada	0	0	0	0	0	1

* Campinas, Cravinhos, Capão Bonito, Gália, Itararé, Jaú, Jundiá, Limeira, Mococa, Monte Alegre do Sul, Pariqueiraçu, Pindamonhangaba, Pindorama, Piracicaba, Ribeirão Preto, Tatuí e Tietê.

As variáveis simuladas devem apresentar um desempenho similar quando comparadas com as variáveis que originam os parâmetros para sua geração. Por intermédio dos resultados verificados anteriormente, observa-se que na grande maioria dos dias do ano, apresentam os dados que aderem à distribuição normal de probabilidade. Então isso também deve ocorrer para as variáveis simuladas. O teste de normalidade aplicado sobre o conjunto de 1000 valores simulados, a partir de cada uma dos tipos de simulação realizados, irá identificar para cada variável o número de aderências (ou rejeições) que os dados simulados irão apresentar. O número de rejeições a distribuição de probabilidade normal é apresentado na Tabela 23, para cada uma das cidades, em cada procedimento de geração dos valores simulados. Por intermédio dos resultados obtidos verifica-se que os valores simulados pela distribuição triangular apresentam rejeição a distribuição normal de probabilidade de 73,40%, para a variável radiação fotossinteticamente ativa e de 45,60% para a temperatura média diária. Já a simulação por intermédio da distribuição normal a 1,96 desvio padrão da média, quase não apresentou rejeições a distribuição normal, somente em aproximadamente 1% dos casos, para ambas as variáveis. Em contrapartida, a simulação dos dados utilizando a distribuição normal bivariada, não apresentou nenhuma rejeição da normalidade aos dados simulados.

Hair et al. (2005) indicam que se a normalidade no sentido univariado não é violada, isso nem sempre resultará que a normalidade multivariada seja respeitada, mas certamente ajuda na obtenção da normalidade multivariada. Porém, a normalidade multivariada significa que as variáveis individuais são normais em um sentido univariado e que suas combinações também são normais. Logo se uma variável é normal multivariada, também é normal univariada. Então, a simulação dos dados por intermédio da distribuição normal bivariada produz resultados mais favoráveis para que a normalidade multivariada não seja rejeitada. No caso dos valores simulados por intermédio das distribuições triangular assimétrica e normal truncada essas certamente resultarão em um maior número de rejeições a distribuição de probabilidade normal multivariada. Santos e Ferreira (2003a) determinaram o tamanho amostral para as estatísticas univariadas (Z_1 e Z_2) e multivariadas (K_1 e K_2), considerando as medidas de assimetria (Z_1 e K_1) e de curtose (Z_2 e K_2). Os autores verificaram que as estatísticas Z_1 e Z_2 possuem aproximações assintóticas normais para $n \geq 25$, com $\alpha = 5\%$ e podem ser recomendadas para uso rotineiro no caso univariado para testar a hipótese de normalidade dos dados. Além disso, as estatísticas K_1 e K_2 possuem aproximações assintóticas melhores que Z_1 e Z_2 para menor valor do nível de significância, sendo

recomendadas para $n \geq 25$ e $n \geq 100$, respectivamente, as quais mantêm o controle da taxa de erro tipo I e elevado poder (poder superior a 80%). E, no caso de distribuições com simetria próxima de zero e não normais, as estatísticas baseadas em desvios de simetria apresentam maior poder do que a estatística W de Shapiro e Wilk (1965).

A verificação da normalidade multivariada é realizada por intermédio da verificação da normalidade da distribuição marginal univariada (BOCK, 1975). Sabe-se que a existência de uma distribuição normal multivariada implica em marginais normalmente distribuídas, porém, não se pode garantir que a distribuição conjunta das duas variáveis normais univariadas sejam uma normal multivariada (SANTOS; FERREIRA, 2003b).

A partir dos resultados da Tabela 25, verifica-se que para os meses de junho, julho, setembro e outubro, a variância entre as localidades foi homogênea para a temperatura mínima, o que não ocorreu nos outros meses.

Com isso, o tamanho amostral pode ser o mesmo para os quatro meses com variâncias homogêneas, para todas as cidades avaliadas. Para a temperatura máxima do ar, os meses com variâncias homogêneas foram janeiro, fevereiro, junho, agosto, setembro, outubro e novembro, podendo-se, assim, estimar o mesmo tamanho de amostra nesses meses para todas as localidades. Essa alternância de resultados pode ser consequência da região avaliada não possuir estações do ano bem definidas, com possibilidades de mudanças bruscas de temperatura. Além do mais, nem todas as regiões possuem uma série de anos contínuos e com o mesmo período avaliado. Certamente, isso possibilitaria melhores inferências, porém, a coleta de dados climatológicos, é variável, devido a diferentes anos de instalações dos postos meteorológicos e disponibilidade dos dados.

Tabela 24 - Número de rejeições do teste de normalidade (Kolmogorov-Smirnov) em cada um dos 17 locais analisados no estado de São Paulo, para os 1000 valores simulados por intermédio das distribuições triangular assimétrica (TRI), normal truncada a 1,96 desvio padrão da média (NT) e normal bivariada (NBV), para radiação fotossinteticamente ativa (PAR) e temperatura média do ar (TEMP)

Locais	PAR			Temp		
	TRI	NT	NBV	TRI	NT	NBV
Campinas	307	2	0	163	4	0
Cravinhos	269	4	0	236	5	0
Capão Bonito	234	3	0	257	7	0
Gália	271	2	0	169	3	0
Itararé	225	2	0	134	4	0
Jaú	327	3	0	136	3	0
Jundiaí	269	4	0	169	4	0
Limeira	155	6	0	115	2	0
Mococa	291	6	0	148	2	0
Monte Alegre do Sul	309	4	0	116	2	0
Pariqueraçu	196	4	0	104	5	0
Pindamonhangaba	295	4	0	164	3	0
Pindorama	294	2	0	154	2	0
Piracicaba	292	3	0	134	2	0
Ribeirão Preto	303	4	0	281	4	0
Tatuí	259	3	0	140	5	0
Tietê	271	4	0	215	5	0
Total*	4567	60	0	2835	62	0
Percentual Total	73,40	1,0	0	45,60	1,0	0

* 17 cidades x 366 = 6222.

Observando os valores para o teste de Bartlett para a variável insolação, nos 18 locais (Tabela 25), verifica-se que somente para o mês de fevereiro o teste de homogeneidade de Bartlett não foi significativo, o que indica que o tamanho de amostra neste caso pode ser a mesma nos 18 locais. No entanto, para os outros 11 meses do ano, obtiveram-se variâncias heterogêneas, indicando que há variabilidade espacial quanto ao tamanho de amostra dos locais avaliados. Existe variabilidade espacial (entre locais) nos 12 meses do ano, quando consideradas as variáveis radiação solar e radiação fotossinteticamente ativa. De maneira geral, essa variabilidade pode ser atribuída às características peculiares de cada local.

Tabela 25 - Valor calculado da estatística do teste de Bartlett (χ^2_{Cal}) das variâncias das variáveis avaliadas para os meses do ano entre os locais do estado de São Paulo

Meses	Temperatura Mínima		Temperatura Máxima		Temperatura Média		Insolação		Radiação Solar		Radiação Fotossinteticamente Ativa	
	χ^2_{Cal}	Sig	χ^2_{Cal}	Sig	χ^2_{Cal}	Sig	χ^2_{Cal}	Sig	χ^2_{Cal}	Sig	χ^2_{Cal}	Sig
Janeiro	186,24	*	31,11	ns	67,42	*	41,67	*	54,60	*	61,06	*
Fevereiro	146,72	*	16,66	ns	66,00	*	27,27	ns	32,69	*	33,97	*
Março	53,04	*	91,74	*	144,12	*	48,24	*	49,38	*	50,10	*
Abril	46,51	*	63,59	*	104,69	*	76,84	*	91,99	*	106,09	*
Mai	90,99	*	50,85	*	95,59	*	67,36	*	65,43	*	64,69	*
Junho	20,93	ns	31,48	ns	95,35	*	109,12	*	105,39	*	111,22	*
Julho	22,13	ns	35,38	*	53,49	*	127,12	*	103,71	*	113,74	*
Agosto	53,62	*	19,51	ns	117,94	*	70,44	*	66,29	*	72,95	*
Setembro	24,83	ns	21,96	ns	75,56	*	37,17	*	40,94	*	42,09	*
Outubro	32,24	ns	22,09	ns	78,95	*	92,13	*	101,12	*	103,32	*
Novembro	95,69	*	15,40	ns	89,10	*	52,98	*	61,83	*	65,29	*
Dezembro	127,50	*	48,95	*	213,55	*	35,50	*	47,18	*	47,57	*

* Significativo em nível de 5% de probabilidade de erro; ns - não significativo.

A avaliação da homogeneidade temporal para as variáveis avaliadas serão apresentadas e discutidas a seguir. Os resultados da Tabela 26 (temperatura mínima) permitem verificar a variabilidade temporal para as 23 localidades testadas pelo teste de homogeneidade de Bartlett. Verifica-se que para 21 localidades as variâncias entre os meses foram heterogêneas. Portanto, foi necessário calcular o tamanho de amostra para cada um dos meses. Apenas para as estações localizadas em Itararé e São Roque, as variâncias entre os meses avaliados não foram consideradas heterogêneas. Com isso, existem locais com variâncias contrastantes entre os meses do ano, a ponto de tornar as variâncias heterogêneas (as 21 localidades) e locais com baixa variabilidade na performance entre os meses (Itararé e São Roque).

Como existe uma grande variabilidade de resultados, indica-se a utilização da maior variância entre os meses do ano para estimar o tamanho da amostra em cada local. No caso dos

locais com variâncias homogêneas, deve-se utilizar o valor médio do tamanho amostral estimado, o que poderá ser utilizado para todos os meses do ano. Para as cidades de Itararé e São Roque (Tabela 26), para a variável temperatura mínima, é suficiente a utilização de 17 e 11 anos (tamanho da amostra). Porém, se o objetivo é a melhor avaliação, deve-se utilizar o máximo valor entre os meses e o máximo valor entre as cidades. Para a temperatura mínima, deve-se utilizar um tamanho de amostra de 53 anos, para assim realizar inferências corretas. Porém, ao verificar que esse valor está acima da série de dados disponíveis, deve-se utilizar o máximo valor obtido para a localidade em questão.

O teste de homogeneidade aplicado para a temperatura máxima (Tabela 26) revela que a variabilidade temporal é menor para esta variável, ou seja, maior número de cidades com variâncias homogêneas ao longo do ano. Nesse caso, as cidades de Assis, Capão Bonito, Jundiá, Pariqueraçu, São Roque, Tatuí e Ubatuba, não apresentaram significância para o teste de homogeneidade, indicando assim que o tamanho de amostra para a temperatura máxima do ar pode ser a mesma, devendo-se utilizar o valor médio.

Para a variável temperatura máxima (Tabela 27) é mais pronunciado o efeito da homogeneidade das variâncias entre os meses do ano, em cada uma das cidades. Para se considerar um número de amostra que seja ótimo para todas as cidades em todos os meses, deve-se utilizar o valor máximo obtido (76 anos), porém, como nem todas as cidades possuem uma série temporal tão extensa, pode-se adotar o máximo de anos obtidos em cada cidade. Sendo que para as localidades cuja homogeneidade de variância não foi rejeitada, esse deve ser o único valor utilizado para todos os meses. Dessa forma, a utilização do tamanho de amostra estimado de 76 anos, para a temperatura máxima do ar é realizada com 95% de confiabilidade de que o erro máximo é de $0,5^{\circ}\text{C}$, independente do mês e do local.

Para a variável temperatura média do ar (Tabela 28), verificou-se que a variabilidade temporal foi homogênea nas seguintes localidades: Capão Bonito, Itararé, Pariqueraçu, São Roque, Tatuí e Ubatuba. Dessa forma, para essas cidades o tamanho de amostra é o mesmo para todos os meses do ano. Porém, para os outros locais, como existe variabilidade temporal, deve-se estimar diferentes tamanhos de amostra para cada um dos meses.

Tabela 26 - Valor calculado da estatística do teste de Bartlett (χ^2_{Cat}) das variâncias da temperatura mínima do ar média mensal de cada mês entre os locais e tamanho de amostra (número de anos) para as estações localizadas nos municípios do estado de São Paulo

Temperatura Mínima																	
Locais	χ^2_{Cat}	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Max	Min	Med	
Adamantina	56,10	*	17	6	7	14	15	13	17	15	10	14	11	6	17	6	12
Assis	48,30	*	1	5	4	10	11	10	13	15	13	12	12	14	15	1	10
Ataliba Leonel	41,39	*	21	6	6	26	27	19	25	18	16	14	20	14	27	6	18
Campinas	33,27	*	16	44	14	32	42	34	40	40	30	40	38	44	44	14	35
Capão Bonito	28,18	*	17	5	7	17	18	18	22	19	12	21	20	13	22	5	16
Gália	38,74	*	10	9	17	19	21	19	22	22	15	15	19	15	22	9	17
Itararé	7,67	ns															17
Jaú	39,10	*	8	6	10	21	26	23	30	18	15	23	24	8	30	6	18
Jundiaí	64,03	*	22	26	21	29	30	27	24	15	9	14	20	6	30	6	20
Limeira	27,59	*	17	5	8	21	24	23	29	22	22	20	18	20	29	5	19
Mococa	117,67	*	35	28	4	19	25	25	27	16	16	18	40	3	40	3	21
Monte Alegre do Sul	78,67	*	3	2	6	12	19	17	18	14	11	10	18	3	19	2	11
Nova Odessa	120,82	*	4	3	4	12	16	15	15	14	11	11	9	3	16	3	10
Pariqueraçu	43,62	*	8	3	4	12	18	15	16	14	4	8	12	3	18	3	10
Pindamonhangaba	32,31	*	10	9	9	9	17	17	18	17	16	17	17	11	18	9	14
Pindorama	78,05	*	2	2	2	19	20	16	24	12	10	9	9	1	24	1	11
Piracicaba	104,96	*	8	9	10	48	53	44	43	36	19	28	29	16	53	8	29
Ribeirão Preto	57,22	*	7	8	10	31	36	28	38	21	20	17	24	19	38	7	22
São Roque	11,53	ns															11
Tatuí	26,04	*	7	4	4	13	14	14	16	11	8	12	14	6	16	4	10
Tietê	37,87	*	5	7	8	11	18	16	17	16	9	16	10	4	18	4	11
Ubatuba	44,42	*	7	5	5	7	13	10	14	12	12	9	18	10	18	5	10
Votuporanga	45,18	*	1	1	2	6	8	8	9	6	5	7	9	1	9	1	5
Max			35	44	21	48	53	44	43	40	30	40	40	44	53		
Min			1	1	2	6	8	8	9	6	4	7	9	1		1	
Med			11	9	8	19	23	20	23	18	13	16	19	10			16

* Significativo em nível de 5% de probabilidade de erro; ns - não significativo.

Tabela 27 - Valor calculado da estatística do teste de Bartlett (χ^2_{Cat}) das variâncias da temperatura máxima do ar média mensal de cada mês entre os locais e tamanho de amostra (número de anos) para as estações localizadas nos municípios do estado de São Paulo

Locais	Temperatura Máxima															
	χ^2_{Cat}	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Max	Min	Med
Adamantina	23,48 *	12	17	15	17	14	19	19	17	18	19	12	14	19	12	16
Assis	17,88 ns															12
Ataliba Leonel	46,37 *	20	27	38	25	17	29	29	32	37	35	22	20	38	17	27
Campinas	49,35 *	42	49	30	35	38	51	54	64	76	65	31	46	76	30	49
Capão Bonito	18,75 ns															19
Gália	38,76 *	8	15	13	13	11	17	20	19	22	21	11	9	22	8	15
Itararé	24,39 *	15	16	14	16	13	16	22	23	24	21	13	14	24	13	17
Jaú	50,55 *	23	30	19	24	18	26	30	30	43	40	21	24	43	18	27
Jundiaí	15,67 ns															20
Limeira	54,22 *	17	26	18	25	17	23	29	32	40	34	26	23	40	17	26
Mococa	59,06 *	22	25	17	10	13	16	23	26	39	31	21	19	39	10	22
Monte Alegre do Sul	34,67 *	9	15	9	4	10	13	15	12	19	17	13	9	19	4	12
Nova Odessa	28,14 *	15	14	9	15	10	12	14	13	16	14	10	16	16	9	13
Pariqueraçu	12,17 ns															15
Pindamonhangaba	32,27 *	18	19	19	12	17	13	19	14	18	18	18	13	19	12	16
Pindorama	61,31 *	14	21	14	7	9	13	19	26	33	28	15	27	33	7	19
Piracicaba	44,64 *	30	40	23	38	49	39	45	48	66	52	36	26	66	23	41
Ribeirão Preto	75,38 *	23	25	16	13	16	20	27	30	52	38	27	19	52	13	26
São Roque	14,94 ns															11
Tatuí	19,02 ns															15
Tietê	22,29 *	13	14	10	7	6	14	15	14	16	15	11	11	16	6	12
Ubatuba	12,32 ns													18		
Votuporanga	30,65 *	7	8	6	5	3	8	9	9	10	10	8	1	10	1	7
Max		42	49	38	38	49	51	54	64	76	65	36	46	76		
Min		7	8	6	4	3	8	9	9	10	10	8	1		1	
Med		18	23	17	16	16	21	24	26	33	29	18	18			20

* Significativo em nível de 5% de probabilidade de erro; ns não significativo.

No caso da melhor estimativa do tamanho de amostra para temperatura média do ar (Tabela 28), verifica-se que, desconsiderando o local e o mês do ano, o melhor número de amostra (anos) deveria ser 70. Porém, como nem todos os locais possuem uma série de anos com essa magnitude, deve-se avaliar individualmente cada local em questão. Porém, para algumas cidades o teste de homogeneidade de variância não foi rejeitado, o que faz o tamanho da amostra ser a média dos valores observados. As cidades onde isso foi verificado são Capão Bonito (14), Itararé (14), Pariqueiraçu (10), São Roque (13), Tietê (9), Tatuí (18) e Ubatuba (9).

A hipótese da homogeneidade das variâncias da insolação não é rejeitada para as cidades de Capão Bonito, Cravinhos, Itararé, Limeira, Pariqueiraçu, Pindamonhangaba e Tietê (Tabela 29). Para a estimação do melhor tamanho de amostra, deve-se utilizar o maior valor dentre os locais durante o ano. Porém, ao considerar isso, o número de anos que representaria qualquer local e época do ano seria 70. Como nem todos os locais possuem essa magnitude de anos avaliados, deve-se analisar individualmente cada um dos locais. Nos locais de Capão Bonito, Cravinhos, Jundiaí, Limeira, Pariqueiraçu, Pindamonhangaba, Tatuí, Tietê e Ubatuba o número de anos é muito próximo ao valor máximo de anos da série histórica. Isso provavelmente indique que o tamanho amostral adequado esteja acima do número de anos avaliados. Esses resultados concordam com CARGNELUTTI FILHO, MATZENAUER, MALUF (2006), que indicam variabilidade do tamanho de amostra para a estimativa da temperatura mínima do ar média mensal no Estado do Rio Grande do Sul, sendo que isso ocorre no tempo e no espaço.

Quanto à radiação solar global (Tabela 30) e à radiação fotossinteticamente ativa (Tabela 31), as variâncias não são homogêneas para alguns locais. Estes resultados indicam que, para localidades em que as variâncias entre os meses do ano são homogêneas, pode-se adotar um mesmo tamanho de amostra (número de anos).

Tabela 28 - Valor calculado da estatística do teste de Bartlett (χ^2_{Cat}) das variâncias da temperatura média do ar média mensal de cada mês entre os locais e tamanho de amostra (número de anos) para as estações localizadas nos municípios do estado de São Paulo

Locais	Temperatura Média															
	χ^2_{Cat}	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Max	Min	Med
Adamantina	20,16 *	15	9	8	13	9	14	16	13	15	14	8	7	16	7	12
Assis	71,45 *	3	4	3	11	8	12	12	15	12	15	15	14	15	3	10
Ataliba Leonel	24,66 *	13	10	23	24	22	22	27	26	27	28	25	29	29	10	23
Campinas	91,88 *	20	29	15	26	30	29	34	56	59	55	20	70	70	15	37
Capão Bonito	15,65 ns															14
Gália	36,72 *	7	7	5	13	12	12	19	17	12	17	18	5	19	5	12
Itararé	10,27 ns															14
Jaú	42,42 *	11	10	7	15	11	14	26	22	33	23	15	9	33	7	16
Jundiaí	22,91 *	12	20	8	22	22	15	19	11	23	13	15	6	23	6	15
Limeira	42,42 *	11	10	7	15	11	14	26	22	33	23	15	9	33	7	16
Mococa	61,95 *	19	14	4	8	12	14	20	13	30	21	33	6	33	4	16
Monte Alegre do Sul	51,03 *	4	5	3	4	15	9	15	4	13	12	18	2	18	2	9
Nova Odessa	38,26 *	9	7	3	12	16	10	15	9	13	11	7	12	16	3	10
Pariqueraçu	17,94 ns															10
Pindamonhangaba	23,09 *	9	6	14	6	14	8	17	10	12	15	14	5	17	5	11
Pindorama	28,38 *	5	8	4	9	8	8	18	11	22	15	7	10	22	4	10
Piracicaba	68,69 *	9	11	8	43	35	17	26	22	25	17	25	7	43	7	20
Ribeirão Preto	31,18 *	29	29	28	48	46	42	50	40	47	36	34	37	50	28	39
São Roque	5,96 ns													14		13
Tatuí	15,27 ns													14		9
Tietê	7,03 ns													19		18
Ubatuba	15,02 ns													15		9
Votuporanga	20,07 *	3	4	2	3	6	7	9	7	7	9	6	1	9	1	5
Max		29	29	28	48	46	42	50	56	59	55	34	70	70		
Min		3	4	2	3	6	7	9	4	7	9	6	1		1	
Med		11	11	9	17	17	15	22	19	24	20	17	14			16

* Significativo em nível de 5% de probabilidade de erro; ns - não significativo.

Em contrapartida, nos locais em que se rejeitou a hipótese da homogeneidade das variâncias ao longo do ano, existe a indicação da existência de variabilidade temporal do tamanho de amostra. Para a variável radiação solar global, verifica-se que o teste de Bartlett não foi significativo para as localidades de Capão Bonito, Cravinhos, Itararé, Jundiá, Limeira e Tietê. Para essas localidades, a variância não varia durante os meses do ano, significando que a intensidade de amostragem deve ser a mesma em todos os meses do ano. Essa hipótese é rejeitada para as outras cidades, indicando a existência de variabilidade temporal para os locais avaliados. A hipótese da variabilidade espacial (Tabela 30) é rejeitada para todos os meses do ano, indicando que existe um tamanho amostral (número de anos) diferente para cada um dos locais avaliados.

O tamanho amostral referente a radiação solar (Tabela 29), que representa qualquer um dos meses do ano, em qualquer local, deve ser aquele que represente a maior variância entre anos. Utilizando o valor máximo, em todos os locais e meses avaliados, temos o tamanho de amostra igual a 73 anos. Porém, como nem todos os locais possuem o mesmo número de anos (amplitude da série histórica), deve-se observar o maior tamanho de amostra em cada um dos locais. No caso da variável insolação, deve-se observar que, em algumas localidades, a amplitude da série histórica é pequena, fazendo que o tamanho amostral seja igual ao número de anos da série histórica, indicando que a magnitude da série histórica deve ser maior para estimar o melhor tamanho amostral.

Para a radiação fotossinteticamente ativa (Tabela 31), verifica-se que a homogeneidade de variância entre os meses (variabilidade temporal) foi rejeitada em Capão Bonito, Itararé, Jundiá, Limeira, Tietê e Ubatuba. Isso indica que para essas localidades existe variância temporal, ou seja, cada mês do ano possui um tamanho de amostra. No caso dos outros nove locais, pode-se utilizar um tamanho de amostra único para qualquer mês avaliado, devido à homogeneidade da variância durante o ano. Também, para a radiação fotossinteticamente ativa, assim como para a radiação solar e a insolação, deve-se avaliar individualmente para indicar o tamanho de amostra. A diferença de magnitude das séries temporais altera a interpretação para cada uma das localidades, não permitindo uma avaliação geral. Neste caso, isso é devido ao tamanho final de amostra ser igual a magnitude da série histórica.

Tabela 29 - Valor calculado do teste de homogeneidade de Bartlett para as variâncias entre os meses (χ^2_{Cal}) da insolação média mensal e tamanho de amostra (número de anos) nos meses do ano, máximo (Max), mínimo (Min) e média (Med) para estações localizadas nos municípios do Estado de São Paulo

Locais	Insolação															
	χ^2_{Cal}	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Max	Min	Med
Campinas	44,29*	40	43	38	37	43	44	43	42	41	36	38	42	44	36	41
Capão Bonito	7,87ns															11
Cravinhos	10,91ns															5
Gália	33,88*	22	22	23	21	23	20	22	24	25	24	21	22	25	20	22
Itararé	9,96ns															22
Jaú	27,37*	38	44	33	39	39	40	32	38	39	36	42	43	44	32	39
Jundiaí	20,47*	7	7	7	6	5	6	6	5	5	5	7	7	7	5	6
Limeira	3,45ns															24
Mococa	50,03*	37	40	39	29	35	29	25	34	37	36	35	39	40	25	35
Monte Alegre do Sul	29,43*	18	18	16	15	19	18	13	17	19	19	16	20	20	13	17
Pariqueraçu	17,13ns															19
Pindamonhangaba	15,29ns															14
Pindorama	29,67*	35	36	34	30	34	35	32	34	35	35	35	35	36	30	34
Piracicaba	41,91*	70	69	62	43	59	59	53	55	63	63	67	70	70	43	61
Ribeirão Preto	34,99*	31	32	28	27	28	25	19	30	31	27	29	33	33	19	28
Tatuí	24,38*	8	8	8	8	7	8	8	9	9	8	8	9	9	7	8
Tietê	11,54ns															5
Ubatuba	22,98*	11	11	11	9	6	8	11	11	11	12	11	11	12	6	10
Max		70	69	62	43	59	59	53	55	63	63	67	70	70		
Min		4	5	5	5	5	4	4	5	5	5	4	4		4	
Med		23	24	22	20	22	21	20	22	23	23	23	24			22

* Significativo em nível de 5% de probabilidade de erro; ns não significativo.

Tabela 30 - Valor calculado do teste de homogeneidade de Bartlett para as variâncias entre os meses (χ^2_{Cal}) da radiação solar global média mensal e tamanho de amostra (número de anos) nos meses do ano, máximo (Max), mínimo (Min) e média (Med) para estações localizadas nos municípios do Estado de São Paulo

Locais	χ^2_{Cal}	Radiação Solar														
		Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Max	Min	Med
Campinas	28,20*	42	44	39	36	42	42	42	42	41	38	41	43	44	36	41
Capão Bonito	17,00ns															11
Cravinhos	17,71ns															5
Gália	61,88*	23	22	23	24	22	17	20	24	25	24	21	22	25	17	22
Itararé	12,80ns															22
Jaú	41,81*	45	44	34	41	40	41	33	39	40	35	40	45	45	33	40
Jundiaí	17,41ns															6
Limeira	9,46ns															24
Mococa	83,01*	39	40	39	28	29	19	38	40	41	38	38	40	41	19	36
Monte Alegre do Sul	39,71*	18	19	17	15	19	16	10	16	19	19	17	20	20	10	17
Pariqueraçu	27,16*	20	20	18	18	18	17	19	17	19	19	19	18	20	17	18
Pindamonhangaba	30,22*	17	18	17	16	15	7	8	8	10	18	18	19	19	7	14
Pindorama	67,19*	35	36	34	29	33	33	28	33	35	36	35	36	36	28	34
Piracicaba	132,24*	73	72	64	39	46	41	37	48	64	67	71	73	73	37	58
Ribeirão Preto	76,23*	32	32	29	26	24	18	12	29	31	29	31	33	33	12	27
Tatuí	29,25*	8	8	8	8	7	7	7	9	9	8	8	9		7	8
Tietê	16,51ns															5
Ubatuba	39,95*	11	11	11	9	4	5	10	11	11	12	12	11	12	4	10
Max		73	72	64	41	46	42	42	48	64	67	71	73	73		
Min		5	5	5	5	4	3	3	5	5	5	4	4		3	
Med		24	24	23	20	21	18	19	22	23	23	23	24			22

* Significativo em nível de 5% de probabilidade de erro; ns - não significativo.

Tabela 31 - Valor calculado do teste de homogeneidade de Bartlett para as variâncias entre os meses (χ^2_{Cat}) da radiação fotossinteticamente ativa média mensal e tamanho de amostra (número de anos) nos meses do ano, máximo (Max), mínimo (Min) e média (Med) para estações localizadas nos municípios do Estado de São Paulo

Locais	Radiação Fotossinteticamente Ativa															
	χ^2_{Cat}	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Max	Min	Med
Campinas	32,45*	42	44	39	34	41	42	42	42	41	38	40	43	44	34	41
Capão Bonito	17,14ns															11
Cravinhos	20,59*	5	5	5	5	5	2	3	5	5	5	5	5	5	2	5
Gália	66,94*	23	22	23	24	22	17	19	24	25	24	21	22	25	17	22
Itararé	11,86ns															22
Jaú	53,72*	45	44	34	39	39	40	32	38	41	35	40	45	45	32	39
Jundiaí	18,00ns															6
Limeira	9,32ns															24
Mococa	93,64*	39	40	39	26	28	17	39	40	41	38	38	40	41	17	35
Monte Alegre do Sul	40,08*	18	19	17	14	18	16	11	16	19	19	17	20	20	11	17
Pariqueraçu	26,74*	20	20	18	18	18	18	19	18	19	19	19	18	20	18	19
Pindamonhangaba	33,31*	17	18	17	16	15	7	8	8	10	18	18	19	19	7	14
Pindorama	75,22*	35	36	34	28	32	33	27	32	35	36	35	36	36	27	33
Piracicaba	149,91*	73	72	64	38	44	39	33	46	65	67	71	73	73	33	57
Ribeirão Preto	83,91*	32	32	29	25	23	17	11	28	31	29	31	33	33	11	27
Tatuí	30,72*	8	8	8	8	7	7	7	9	9	9	8	9	9	7	8
Tietê	15,90ns															5
Ubatuba	19,02ns															10
Max		73	72	64	39	44	42	42	46	65	67	71	73	73		
Min		4	5	5	5	5	2	3	5	5	5	4	4		2	
Med		24	24	23	20	20	18	18	21	23	23	23	24			22

* Significativo em nível de 5% de probabilidade de erro; ns - não significativo.

A amplitude do tamanho de amostra é bastante acentuada nas três variáveis, indicando grande heterogeneidade das variâncias, ou seja, grande variabilidade das condições ambientais para os locais avaliados. Com isso, ao utilizar-se 30 anos de forma generalizada, como recomenda a World Meteorological Organization (WMO), em nota técnica número 82 (THOM, 1966), não existe uma abrangência total dos dados de cada local e em cada época do ano, o que leva a estimativas com diferentes níveis de erros associados. Porém, autores como Frizzone et al. (1985)

e Vernich e Zuanni (1996) afirmam que tais observações podem ser desconsideradas para algumas variáveis, devendo ser utilizada a série de dados disponíveis.

O critério de separação de grupos utilizado no método de Ward (Figura 11) foi de 40%. No caso da temperatura mínima, verificou-se a formação de dois grupos distintos. O primeiro grupo foi formado por janeiro, fevereiro, março, dezembro, abril, outubro e novembro, que são os meses onde a temperatura média do ar está mais elevada. E o segundo grupo foi formado por maio, setembro, junho, julho e agosto, sendo os que possuem a temperatura média do ar mais baixa, além de ser o período com menor frequência de chuvas. Comparando-se esses resultados com os obtidos para a variável temperatura máxima do ar, verifica-se que o segundo grupo formado possui como integrantes os meses de maio, junho e julho. Dessa forma, tanto na temperatura mínima quanto na máxima, o grupo base de meses com temperaturas mais inferiores é composto pelos meses de maio, junho e julho.

A formação de grupos nas localidades é diferenciada para as variáveis temperatura mínima, máxima e média. No caso da temperatura mínima, a menor variabilidade ocorre nos municípios de Jaú, Ribeirão Preto, Mococa, Pindorama, Pariquera, Ubatuba, Adamantina e Votuporanga. Para a variável temperatura máxima do ar, ocorre a repetição no grupo das cidades menos variáveis como Jaú, Mococa, Ribeirão Preto, Pindorama, Adamantina e Votuporanga. No caso da temperatura média do ar, verificam-se a homogeneidade entre o grupo de meses formado por maio, agosto, setembro, junho e julho (meses com maior variabilidade). Para a homogeneidade entre as cidades, considerando um critério de ligação de 40%, não obteve-se a separação de grupos, somente a partir de 35% houve a formação de dois grupos. Onde o grupo com maior variabilidade é formado por Mococa, Ribeirão Preto, Pindorama, Pariqueraçu, Ubatuba, Pindamonhangaba, Nova Odessa, Adamantina e Votuporanga.

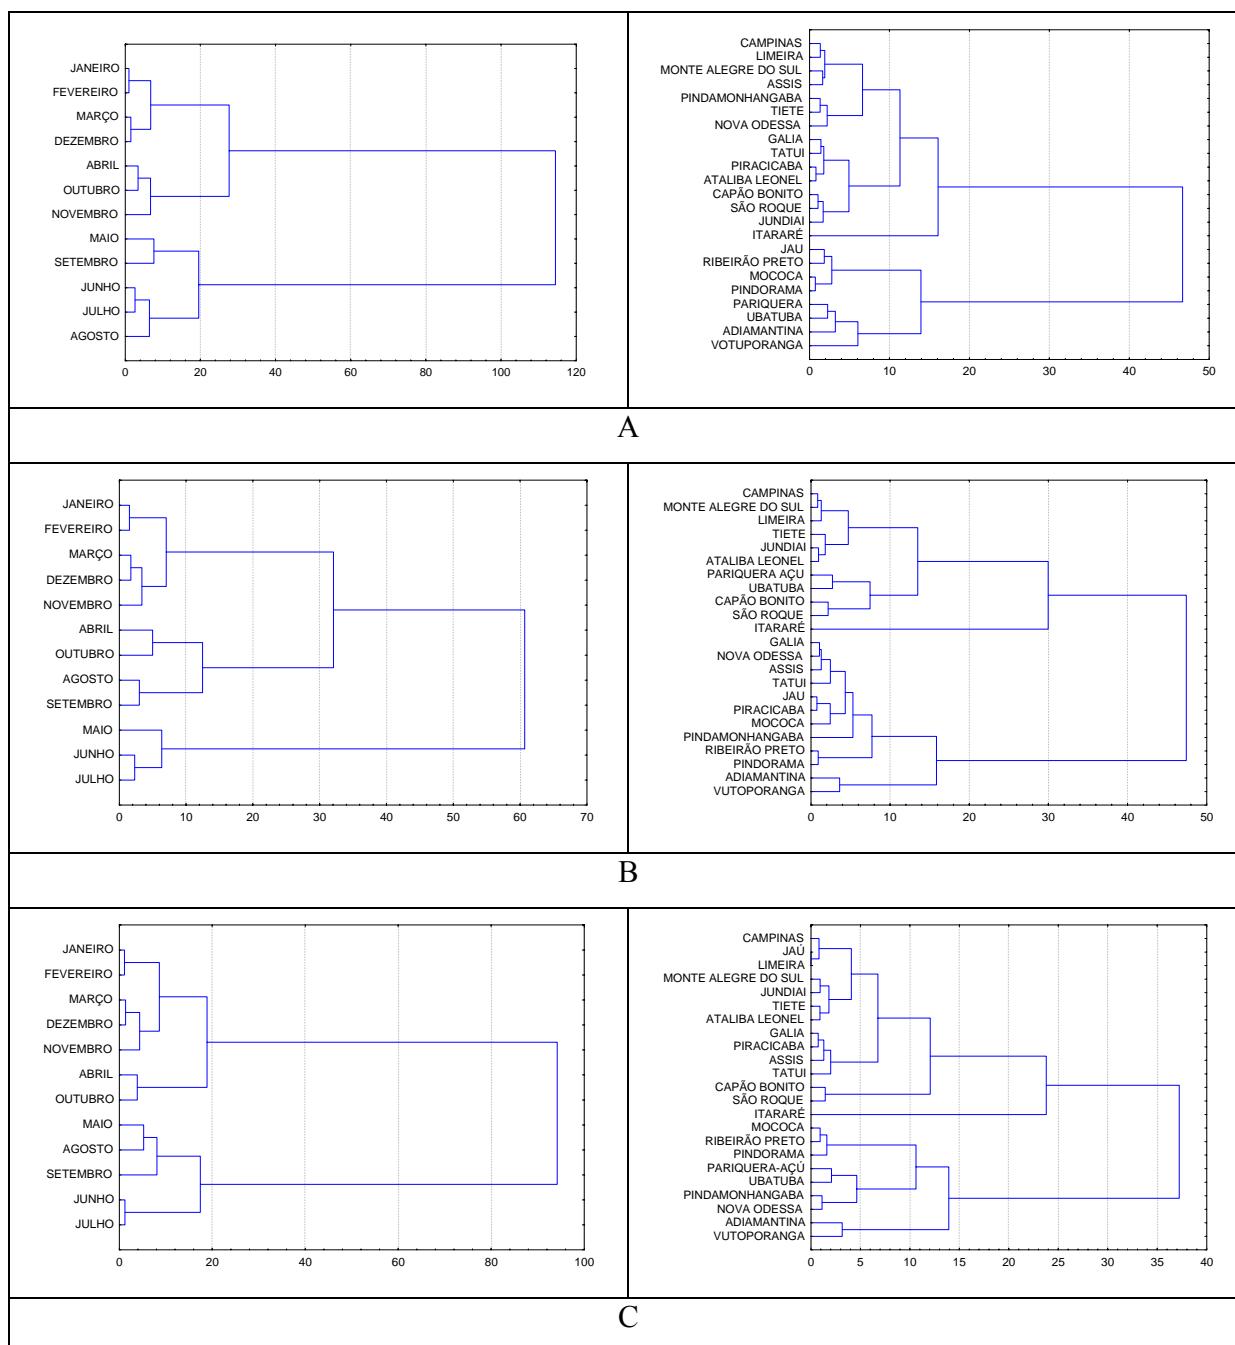


Figura 13 - Dendrogramas da dissimilaridade da temperatura mínima (a), máxima (b) e média (b) do ar, média mensal, entre os meses do ano e os 23 municípios do Estado de São Paulo, obtido pelo método de agrupamento de Ward, baseado na distância euclidiana (média padronizada)

Utilizando de metodologia similar, Diniz et al. (2003) identificaram as regiões homogêneas de temperatura máxima e mínima no Rio Grande do Sul (Brasil). Esses autores ressaltam que essas regiões homogêneas determinadas servirão de subsídios a estudos mais detalhados dos regimes térmicos do Estado, bem como em zoneamentos climáticos e agroclimáticos.

O critério para a definição dos grupos entre os locais e os meses do ano é variável, dependendo da amplitude dos dados para as variáveis insolação, radiação solar e radiação fotossinteticamente ativa (Figura 15). De modo geral, optou-se pela formação de três grupos. Desta forma, para a variável insolação, agruparam-se os meses de janeiro, dezembro e fevereiro como um grupo mais diferenciado dos demais meses do ano. O segundo grupo foi formado pelos meses de março, maio, junho, outubro, novembro e setembro. E como terceiro grupo, os meses de abril, julho e agosto foram os meses de transição. Dentre os municípios com as características mais próximas, quanto à insolação, pode-se agrupar Campinas, Pindorama, Jundiá, Monte Alegre do Sul, Piracicaba, Tietê, Cravinhos, Jaú, Mococa e Ribeirão Preto. Esse primeiro grupo possui características mais próximas ao segundo grupo (Capão Bonito, Itararé, Gália, Pindamonhangaba e Tatuí). Contudo, o grupo mais diferenciado, quanto às características de insolação, é formado pelos locais de Limeira, Pariqueraçu, e Ubatuba.

Para a radiação solar global (Figura 15), verifica-se que o grupo mais distinto foi formado pelos meses de maio, junho e julho (menores médias mensais de RS). O grupo de transição foi formado pelos meses de abril, setembro e agosto, onde esses meses precedem o início do período do inverno (abril) e o período de verão (setembro e agosto). Quanto à dissimilaridade dos locais avaliados, a formação de três grupos ocorre com uma distância de ligação de 400, onde os locais de Limeira, Pariqueraçu e Ubatuba são próximos entre si, porém, é o grupo com as características de radiação solar mais contrastante entre os locais avaliados. Em contrapartida, o grupo com as características mais próximas entre si é formado pelos locais de Campinas, Pindorama, Monte Alegre do Sul, Piracicaba, Tietê, Cravinhos, Mococa, Ribeirão Preto, Capão Bonito, Gália, Pindamonhangaba e Tatuí, onde existem as menores distâncias de ligação (maiores médias mensais de radiação solar).

A formação de grupos de dissimilaridade para a variável radiação fotossinteticamente ativa, ao longo do ano, não segue o mesmo agrupamento da variável radiação solar global, porém

com uma distância de ligação menor. Quanto aos locais que estão agrupados nos mesmos grupos a formação de três grupos ocorre numa distância de ligação de 200.

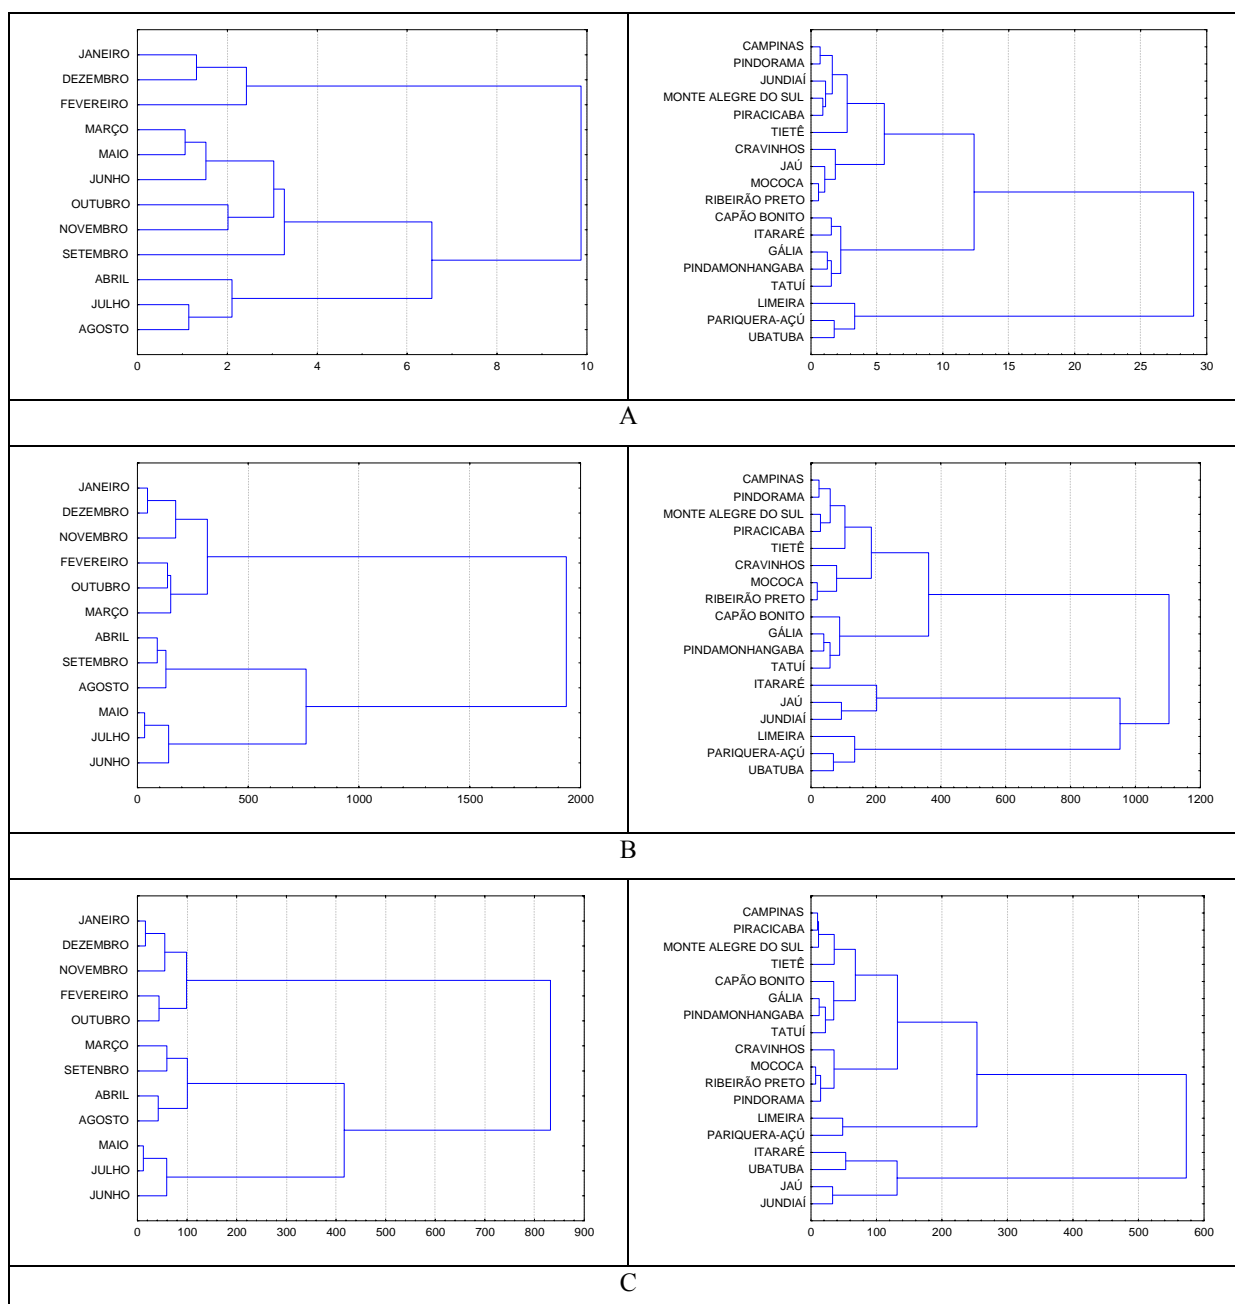


Figura 14 - Dendrogramas da dissimilaridade das médias mensais da insolação (a), da radiação solar global (b) e da radiação fotossinteticamente ativa (c) entre os meses do ano e as 18 localidades do Estado de São Paulo

O grupo com as médias de radiação fotossinteticamente ativa mais diferente das outras cidades é formado pelos locais de Itararé, Ubatuba, Jaú e Jundiaí. O maior grupo é formado pelos locais de Campinas, Piracicaba, Monte Alegre do Sul, Tietê, Capão Bonito, Gália, Pindamonhangaba, Tatuí, Cravinhos, Mococa, Ribeirão Preto e Pindorama, sendo que esses locais possuem características bastante próximas entre si, quanto à radiação fotossinteticamente ativa.

A Tabela 10 apresenta as precipitações médias mensais para todos os locais avaliados, juntamente com o seu desvio padrão. Percebe-se que nos meses de junho, julho e agosto, as precipitações ocorrem com menor frequência e com menor intensidade. Isso pode ser verificado na Figura 13, no grupo caracterizado como grupo dos meses secos, nos meses de junho, julho e agosto, essa intensidade é maior, diferenciando-se dos meses de abril, setembro e maio. Porém, esses últimos ocorrem antes ou depois do período mais seco, e representam uma preparação (diminuição gradual) da intensidade de precipitação. Em contrapartida, os meses em que ocorrem a maior intensidade de precipitação pluvial são dezembro e janeiro. E, juntamente com o mês de fevereiro, são classificados pelo método de Ward, como o grupo de meses chuvosos (Figura 13). Um correto planejamento de cultivos de sequeiro deve basear-se nessas informações, pois os cultivos devem coincidir o período de maior exigência hídrica com o período de maior disponibilidade do ambiente. Devido às elevadas variações de precipitação, representadas pelo desvio padrão da Tabela 10, existe dificuldades em prever com maiores precisões as datas prováveis de chuva. Utilizando-se a mesma metodologia, LYRA et al. (2006) determinaram regiões homogêneas baseadas na sazonalidade da precipitação pluvial mensal, no estado de Táchira (Venezuela). Com base nos resultados, esses autores concluem que a variação sazonal da precipitação pluvial apresenta três períodos distintos. Uma importante aplicação prática do agrupamento estatístico de estações meteorológicas é o preenchimento de falhas na série de dados. GARCIA (2005), ao estimar a precipitação diária para estações meteorológicas agrupadas estatisticamente, obteve elevada concordância entre os valores medidos e aqueles preenchidos, com base nos dados obtidos em estações meteorológicas similares. Considerando que é comum a ocorrência de falhas em séries de dados meteorológicos, esse procedimento surge como uma valiosa ferramenta para contornar tal problema. Por intermédio da Tabela 10 e Figura 13, verifica-se que o local de maior precipitação pluvial é Ubatuba, sendo que esse local é contrastante com todas os outros locais avaliados no estado de São Paulo.




Figura 15 - Dendrogramas da dissimilaridade da precipitação pluvial, entre os meses do ano e as 18 localidades do Estado de São Paulo, obtido pelo método de agrupamento de Ward, baseado na distância euclidiana média padronizada

Os resultados gerados podem ser utilizados no auxílio da identificação da progressão de uma doença dentro do estado de São Paulo, pois, ao conhecer-se a similaridade espacial e temporal dos locais e sabendo-se onde a doença já está instalada é possível aplicar medidas que visem à proteção das culturas. Além disso, a partir das características do ano corrente, é possível comparar com os resultados da base de anos da série histórica e assim melhorar as indicações de época de plantio (temperaturas favoráveis ao desenvolvimento da cultura) e aplicações de tratamentos culturais. No caso da utilização da técnica de simulação de dados não é necessário analisar ou obter todos os dados de uma região ou época do ano considerada homogênea, o que melhorará o processo de tomada de decisões com o mesmo grau de confiança.

Dessa forma, por intermédio de uma análise conjunta das figuras e tabelas, verifica-se que existe uma variabilidade espacial e temporal no tamanho de amostra para o número de anos avaliados em cada cidade e/ou em cada mês do ano. Esses resultados concordam com Cargnelutti Filho et al. (2006), que também relatam que o uso de 30 anos de observações não contempla a variabilidade espacial e temporal, o que pode causar interpretações tendenciosas pelo uso insuficientes do número de anos observados.

Os resultados das 500 simulações para cada uma das 25 localidades nas 36 épocas de semeadura estão apresentadas na Figura 16. Como o objetivo da tese é propor um modelo para a estimativa das produtividades potencial e deplecionada para a cultura de soja, será enfatizada mais a questão da eficiência do modelo apresentando as suas particularidades, em contrapartida, assuntos referentes a melhores épocas e locais de semeadura serão abordados mais superficialmente, de modo preparativo para estudos futuros.

Verifica-se a partir dos resultados da Figura 16, que o modelo proposto gera valores de produtividade potencial e deplecionada contrastantes quando a simulação de data de semeadura ocorre a cada 10 dias. Isso é decorrente das diferentes condições de temperatura média do ar, radiação fotossinteticamente ativa, fotoperíodo e precipitação disponível em cada uma das épocas de cultivo.

As curvas de produtividade potencial (mínima, máxima e média) possuem o comportamento resultando em maiores produtividades quando semeadas próximas ao período de setembro a outubro, devido as características do ambiente estarem próximas as características de exigência da cultura. Com semeaduras realizadas nessas épocas, a temperatura é tal que permite que o desenvolvimento vegetativo não seja demasiadamente acelerado, permitindo assim que a planta forme uma área foliar (fonte de carboidratos) adequada e suficiente para a produção de carboidratos que serão convertidos em produção de grãos. Na medida que avançamos a época de semeadura em direção a janeiro e fevereiro, as temperaturas são mais intensas, fazendo com que o período vegetativo seja reduzido, reduzindo também a produção final. Juntamente a isso, deve-se considerar o efeito do fotoperíodo, que é máximo no dia 22 de dezembro. Isso quer dizer que na fase vegetativa da planta de soja, haverá uma oferta muito grande de radiação fotossinteticamente ativa, o que estimulará o crescimento, principalmente em condições de ausência de restrição hídrica (produtividade potencial). A medida que ocorre o crescimento e desenvolvimento da planta, concluindo a fase vegetativa, a planta passará a ser influenciada pelo fotoperíodo, e esse estímulo resultará na formação dos órgãos reprodutivos.

Cultivares de soja com maturação tardia, são geralmente mais sensíveis ao fotoperíodo em comparação com cultivares precoces (LAWN; BYTH, 1973; MAJOR et al. 1975b), justificando assim, a utilização dos parâmetros da Cultivar Ocepar 8, para a determinação do número de dias entre a germinação e a floração.

Pelo modelo proposto, o número de dias entre a germinação e o florescimento é função da interação entre os fatores temperatura e fotoperíodo, conforme apresentado por Rodrigues et al. (2001). Segundo esses autores, esse modelo contempla valores mínimos e máximos para temperatura e fotoperíodo, que variam de 19 a 32 °C (temperatura) e 11 a 14 horas (fotoperíodo). Como no presente estudo existem temperaturas médias diárias inferiores a 19 °C, o modelo pode apresentar alguma deficiência nesse sentido, gerando valores bastante contrastantes, como as produtividades geradas quando a semeadura é realizada no período em que a temperatura média diária é inferior a esse valor. Ainda segundo esse modelo de cálculo do número de dias para o florescimento, deve-se considerar que quanto maior a temperatura menor o efeito do fotoperíodo sobre o número de dias necessários para o florescimento, o que faz com que o número de dias seja por volta dos 35 dias quando a temperatura estiver por volta dos 32 °C. Possuindo uma amplitude de 40 a 120 dias numa temperatura de 19 °C, por exemplo. Em termos práticos, deve-se ainda considerar o efeito do genótipo que será utilizado, fazendo com que essa interação tripla (genótipo-temperatura-fotoperíodo) seja extremamente difícil de ser explicada e representada matematicamente. Considerando essa inter-relação tripla complexa, o modelo representou razoavelmente bem o comportamento das produtividades potenciais, pois reduziu o ciclo quando a temperatura foi elevada, mas, devido a alta disponibilidade de radiação solar, houve uma produção bem superior em comparação aos períodos com um fotoperíodo longo, onde o número de dias do ciclo foi maior, mas devido a reduzida quantidade de energia no ambiente, a produção de área foliar foi baixa, limitando assim a fonte de carboidratos e, conseqüentemente, a produtividade.

O índice de área foliar é um dos parâmetros mais importantes ao se trabalhar com questões ligadas a modelagem na produção agrícola. Além disso, é bastante complexo, pois esse parâmetro é função da interação de outros, o que faz com que muitos dos principais pesquisadores tenham evitado a utilização direta, como por exemplo, De Wit (1978). Muitos modelos trazem em seus cálculos valores médios durante o ciclo de desenvolvimento da cultura, porém, para fazer com que os resultados sejam mais precisos e eliminar muitas questões empíricas que auxiliam na solução do problema, a utilização de equações matemáticas, que resultam valores diários do IAF, variando em função do desenvolvimento relativo são desejados. O IAF será maior quanto maior for a energia presente no ambiente capaz de impulsionar a produção de carboidrato pelas plantas. Essa relação não é linear e indefinida devido a planta possuir drenos de energia (respiração). Essa

por sua vez, aumenta gradativamente em função do tamanho da planta, até um determinado momento que se existisse um crescimento indeterminado existiria um respiração maior que a fotossíntese bruta, o que causaria um colapso na planta por ela consumir mais do que ela consegue produzir fotossinteticamente. Dessa forma, a planta, através de sistemas de auto-regulação, limita o seu IAF, freqüentemente apresentado como uma parábola ou algo semelhante nos textos explicativos. Essas limitações impostas pela plantas foram reproduzidas como os fatores de depleção do desenvolvimento relativo e do índice de área foliar (Figuras 10 e 11).

O IAF máximo da planta deve ser truncado para evitar que exista uma área foliar que consuma mais (respiração) do que a capacidade produtiva da planta. Deve-se atentar sempre para fatores como o auto-sombreamento, a perda da capacidade fotossintética com o envelhecimento dos tecidos, dentre outros, que são naturalmetne regulados pelas plantas, e no caso da construção de modelos, esses fatores devem ser contemplados, assim como os modelos propostos por Pereira e Machado (1986). No caso da cultura de soja, o IAF máximo obtido por Câmara e Heiffing (2000), em Piracicaba (SP), variou de 5 a 8. No presente modelo, o valor máximo de IAF foi limitado em 5, para evitar que exista esse maior consumo de carboidratos em relação a sua produção.

A experimentação agrícola deveria ser incentivada e direcionada para estudos relacionados a parâmetros fisiológicos e morfológicos referentes as culturas agrícolas, principalmente soja. Apesar dessa cultura constituir um dos principais grãos exportados pelo Brasil, produções científicas são tímidas e, muitas vezes, os resultados chegam defasados aos seus utilizadores. A melhoria na estimação dos valores de IAF seria fundamental para a melhoria no presente modelo. Não obstante aos problemas do IAF, estão as questões relacionadas a área foliar específica, que possui os parâmetros balisados por cultivares americanas dos anos 70/80, que possuem um comportamento totalmente distinto das cultivares brasileiras, mas por falta de estudos relacionados aos valores citados na literatura, são utilizados com freqüência. Apesar da literatura internacional ser respeitada e até mesmo muitas vezes recomendada, o Brasil possui uma diversidade de genótipos e clima (ambiente) que faz com que a morfologia e fisiologia da planta de soja seja única para cada situação (genótipo x ambiente). Como existe uma distância temporal e espacial da fonte produtora de dados (publicações estrangeiras), fica difícil entender como foram obtidos, em que condições, ou até mesmo, muitas vezes, quais relações foram utilizadas. A utilização de parâmetros empíricos na construção de um modelo matemático é freqüente em

todos os grupos de pesquisa. No momento em que houver incentivo de práticas experimentais para resolver esses problemas, haverá uma melhor qualidade nos modelos produzidos. Muitas informações específicas do funcionamento fisiológico da planta de soja ainda não foram completamente esclarecidas, com isso, muitas vezes, utilizam-se relações empíricas, baseadas em outros conhecimentos. Certamente, essas relações deverão ser questionadas através de experimentação a campo, que objetiva a obtenção de dados e a indicação de evidências.

Os valores de assimilação máxima de dióxido de carbono, foram obtidos através de uma equação que baseou-se em resultados não produzidos em nível nacional. Apesar disso, os valores obtidos estiveram bastante próximos dos valores de máxima assimilação de dióxido de carbono apresentado por diversos autores. A variação anual da produtividade de grão também é função da assimilação de dióxido de carbono, que varia em função da energia presente no ambiente, como comentado anteriormente, sendo a produção bem menor quando realiza-se semeaduras no período com temperatura e fotoperíodo baixos. Esse modelo de estimação da assimilação do dióxido de carbono utilizado é bastante interessante, por que ele considera além da radiação solar fotossinteticamente ativa, a quantidade de dióxido de carbono presente na atmosfera. Apesar de ser extremamente prejudicial para o planeta num contexto geral, o aumento da quantidade de dióxido de carbono no ambiente aumentaria cerca de 22-32% a produção de grãos de soja na região de São Paulo (SIQUEIRA et al., 1994). Independente do valor atual de dióxido de carbono no ambiente, isso seria facilmente ajustado pelo modelo proposto. Porém, os parâmetros empíricos poderiam ser mais precisos se fossem ajustados a partir de resultados experimentais realizados com genótipos utilizados nacionalmente.

Logicamente, proporcionando as melhores condições de desenvolvimento da cultura, é possível obter os melhores resultados produtivos. Quanto a temperatura, as melhores assimilações de dióxido de carbono ocorrem entre 30 e 35 °C, e isso ocorre com maior frequência a partir de setembro. Quando os valores de temperatura não estão dentro desses intervalos, deve-se aplicar uma redução (Figura 1), em que esses valores e parâmetros certamente seriam diferentes no caso de genótipos nacionais.

Apesar da grande utilização dos parâmetros obtidos por outros genótipos que não os nacionais, o comportamento da magnitude da produtividade demonstra que é possível utilizar o modelo como ferramenta do gerenciamento agrícola da cultura de soja. Dessa forma, pode-se

simular situações em baixo custo, mas com uma grande potencialidade de extração de informações.

Segundo o modelo proposto, existe a possibilidade do cultivo anual de soja (sem deficiência hídrica), apesar das baixas produtividades. Deve-se ressaltar alguns pontos importantes a esse respeito. A inexistência de resultados experimentais dificulta comparações com os resultados obtidos, além disso, o fator de depleção em função da baixa temperatura poderá comportar-se de forma diferente do modelo, inviabilizando o cultivo. Os valores mínimos bastante baixos indicam uma grande possibilidade de frustração de safra, apesar da média estar em um patamar razoável. As interações da planta com o ambiente devem ser levadas em consideração, onde não há estudos referentes que possa embasar essa prática. Teoricamente é possível o cultivo durante todo ano, desde que somente a temperatura e a radiação fotossinteticamente ativa sejam os limitantes.

O planejamento agrícola da região deve ser realizado com base em estudos como esse, além de levar em consideração a magnitude da diferença entre as produtividades nas diferentes datas de semeadura e regiões. Sincronizado a esse estudo devem estar os estudos sociais e econômicos, além da diversificação das culturas de acordo com a necessidade e pretensões nacionais de produção.

Segundo Cooper (2003), nos Estados Unidos, os recordes de produtividades variaram de 4.000 kg.ha⁻¹ (1966) até 7.911 kg.ha⁻¹ (1983). Na Austrália, as produtividades máximas variaram de 8.004 a 8.604 kg.ha⁻¹ (1983). Apesar desses elevados valores de produtividade, a produtividade genética da cultura de soja chega a 18.000 kg.ha⁻¹ (florescimento), decaindo para 4.600 kg.ha⁻¹, no ponto de maturidade fisiológica (VENTIMIGLIA et al., 1999). Outros resultados expressivos foram obtidos por Nishi e Hungria (1996), que obtiveram produtividades superiores a 4000 kg.ha⁻¹ em parcelas experimentais trabalhando com reinoculação. Outros experimentos a campo apresentam valores elevados da produtividade de soja, como os de Pires et al. (2000), que estimaram um potencial de rendimento médio de 15.007 kg.ha⁻¹ em R₂ e de 10.282 kg.ha⁻¹ em R₅, sendo este influenciado pelo espaçamento entre linhas, no qual em 20cm obtiveram 10.962 kg.ha⁻¹ e em 40cm 9.602 kg.ha⁻¹. Em experimentação a campo no estado do Rio Grande do Sul, os valores de produtividade variaram de 3.929 kg.ha⁻¹ (OCEPAR) até 6.436 kg.ha⁻¹ (FT-2003) no ano agrícola de 96/97 (NAVARRO JÚNIOR; COSTA, 2002).

Quanto as produtividades deplecionadas em função da precipitação (Figura 16), verifica-se que os valores simulados para precipitação foram semelhantes aos valores observados. Apesar de não terem sido realizados testes para verificar a precisão e a exatidão dos valores simulados de chuva em relação aos valores observados, por comparação de estatísticas básicas (média, mínimo, máximo e frequência, dados não apresentados), pode-se utilizar esse tipo de simulação para a representação da precipitação em uma região. Questões relacionadas a simulação de dados de chuva são bastante peculiares e certamente exigem estudos futuros, através da comparação de metodologias para buscar uma melhor aproximação dos dados simulados com relação ao que acontece na realidade, principalmente quando analisamos que dados diários de chuva são auto-correlacionados, assim como dados de temperatura.

Verifica-se que o fator de depleção em função da sensibilidade da cultura a deficiência hídrica (K_y) atuou intensamente na depleção das produtividades potenciais. A maior subdivisão em um maior número de classes de K_y , em função do desenvolvimento relativo, proporcionou maiores reduções nas produtividades potenciais em comparação com o original proposto por Driessen e Konijn (1992). Além disso, a representação da realidade seria mais fidedigna se o coeficiente de cultura fosse melhor representado (até mesmo em escala diária), para assim melhorar o presente modelo.

Com o objetivo de aproximar-se das situações vivenciadas pela planta de soja, a utilização dos valores diários de chuva no balanço hídrico projeta uma visão mais real do ambiente. Com isso é possível verificar diariamente a situação de estresse hídrico ou não conferido a planta de soja.

A dependência da chuva faz com que, geralmente, a época de semeadura seja atrasada em relação a situação de ausência de estresse. Essa adequação da época de semeadura em relação aos períodos com maior precipitação (novembro, dezembro e janeiro), faz com que seja suprido as necessidades hídricas da plantas nos seus momentos mais críticos (floração e a máxima formação de vagens, BERLATO; BERGAMASCHI, 1979).

O coeficiente de sensibilidade da cultura ao estresse hídrico (K_y) potencializa o efeito dos fatores de correção e da senescência da cultura, reduzindo ainda mais a produtividade de grãos. Com o estresse hídrico, existe a redução do período vegetativo (formação de massa) e reprodutivo (transferência de fotoassimilados). Nessa situação, semeaduras a partir do último decêndio de

janeiro até os primeiros decêndios de setembro tornam-se extremamente arriscados pelas baixas produtividades e aumento significativo das frustrações de safra.

Em termos de risco climático, que é a relação entre a produtividade deplecionada e a produtividade potencial, observa-se que existe uma interação muito grande de acordo com a época de semeadura e local. Essa relação pode ser amplamente estudada e discutida em um momento mais adequado, porém, serão realizadas algumas considerações gerais para nortear estudos futuros. Em média, a partir do mês de setembro, o risco climático de frustração de safra reduz-se devido a amplitude entre a relação de produtividade deplecionada e potencial ser menor e os valores mínimos estarem em torno de 60%. Ou seja, as produtividades deplecionadas representam mais de 60% da produtividade potencial. Enquanto que no período de fevereiro a agosto, as produtividades deplecionadas representam em algumas regiões 19% das produtividades potenciais. Em termos médios, de fevereiro a agosto, os valores das relação situam-se abaixo dos 60%, o que certamente inviabiliza o cultivo em determinadas regiões. As menores relações são observadas entre os meses de maio e junho onde as produtividades deplecionadas representam em média 20 a 30%, porém, em determinados locais chegam a 1%. Estudos de risco climático podem ser melhor conduzidos através da análise de agrupamento para os locais e datas de semeadura, o que otimizará os dados obtidos.

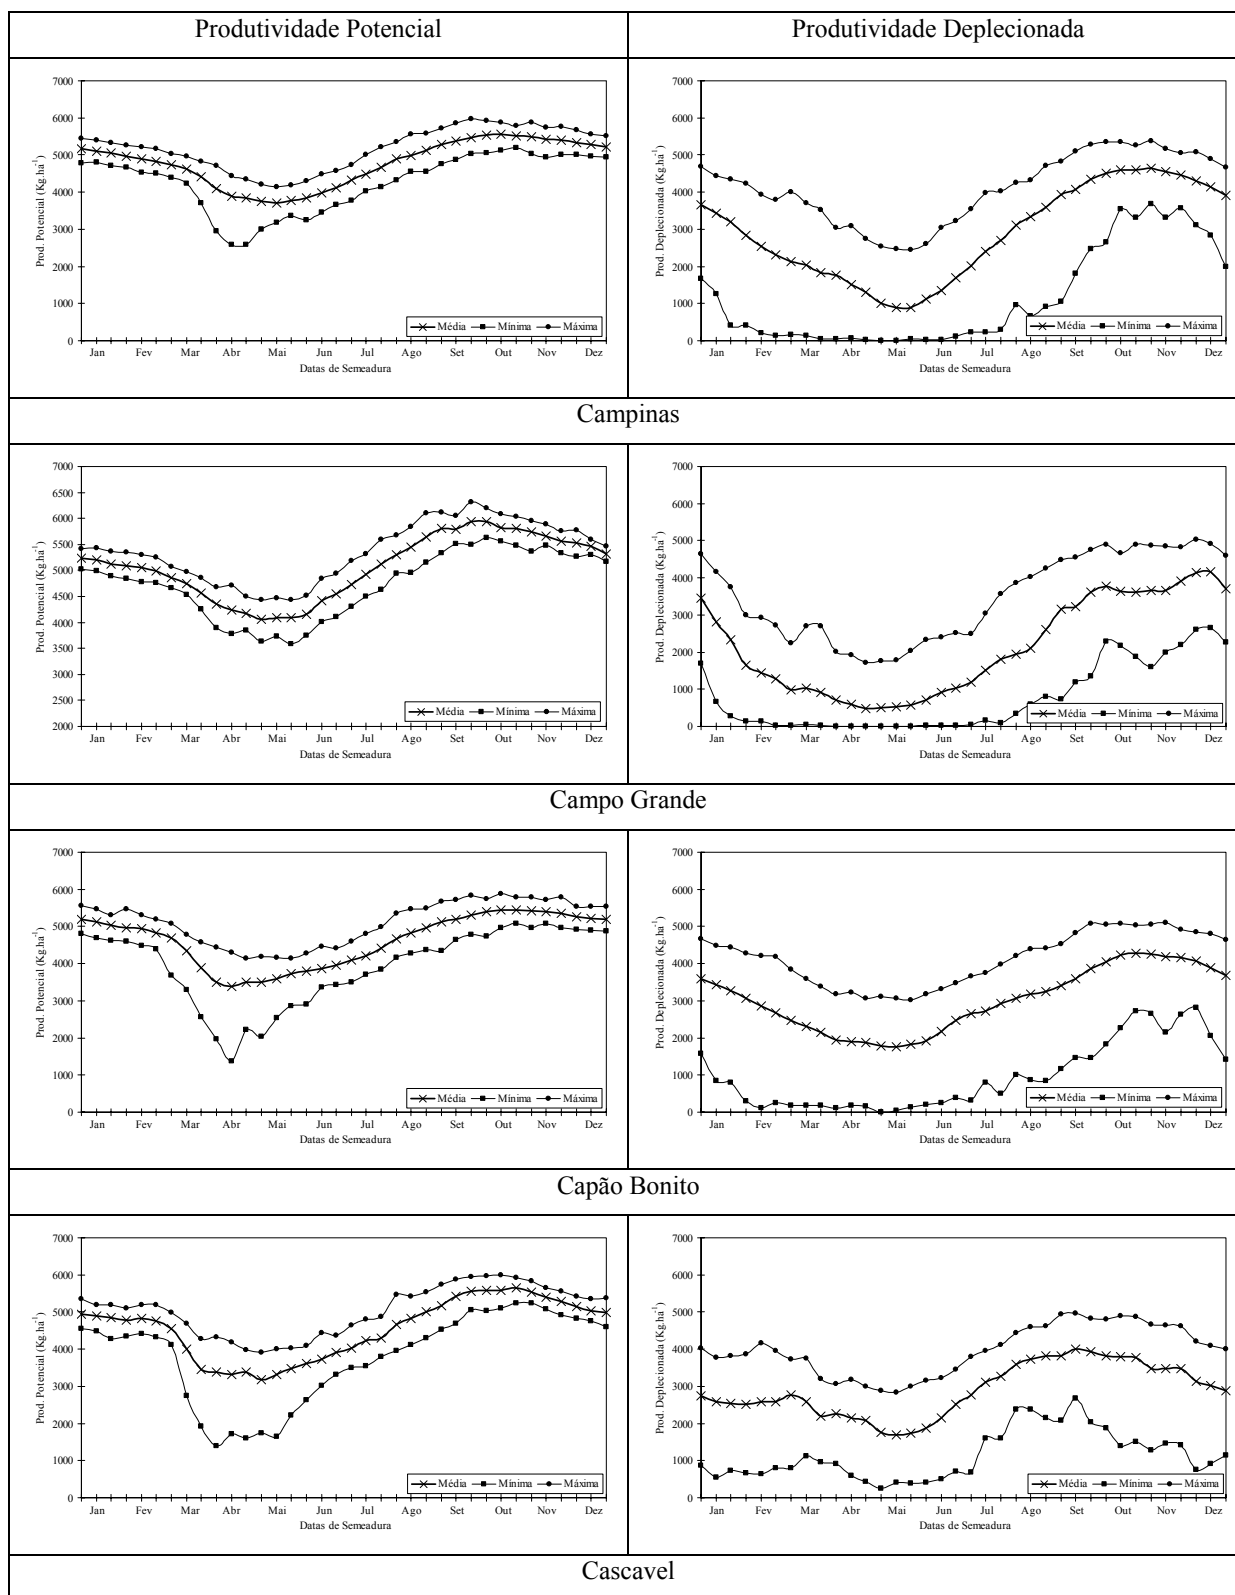


Figura 16 - Produtividade média, mínima e máxima durante as 36 datas de semeadura, obtidas através da simulação normal bivariada, valores referentes a 500 simulações (início)

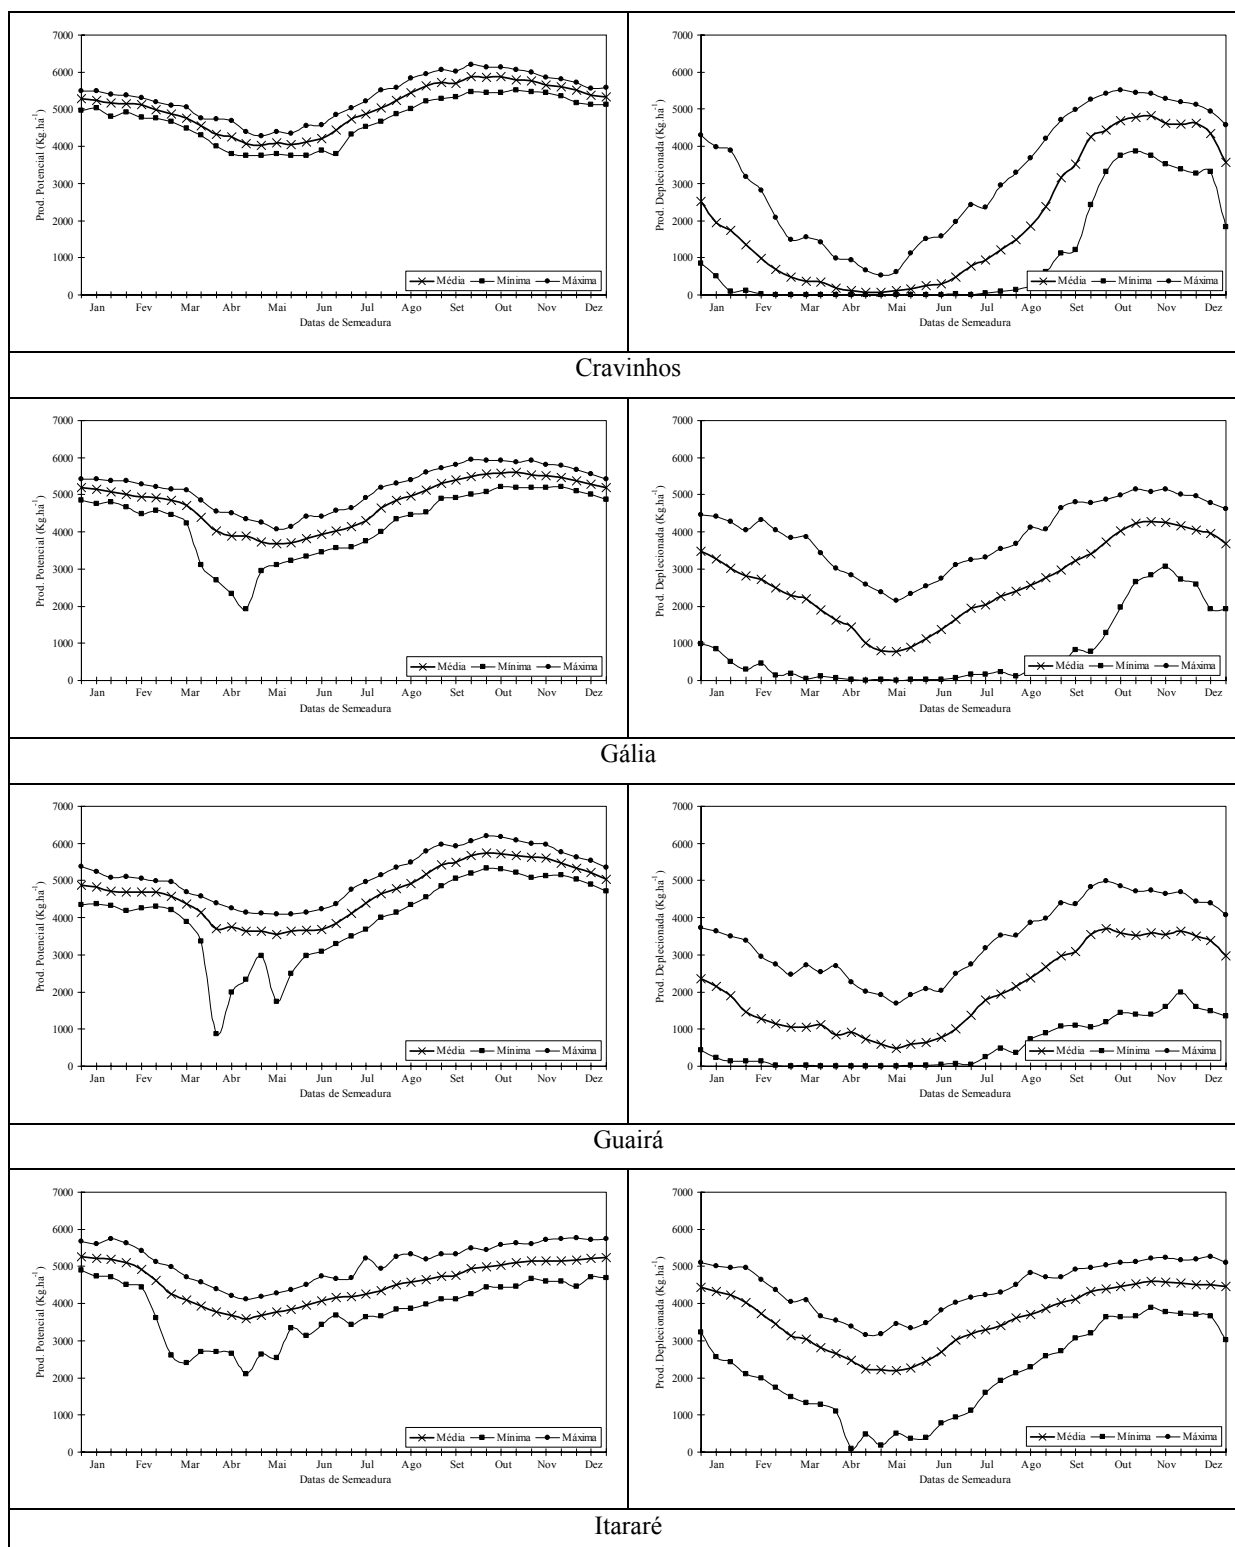


Figura 16 - Produtividade média, mínima e máxima durante as 36 datas de semeadura, obtidas através da simulação normal bivariada, valores referentes a 500 simulações (continuação)

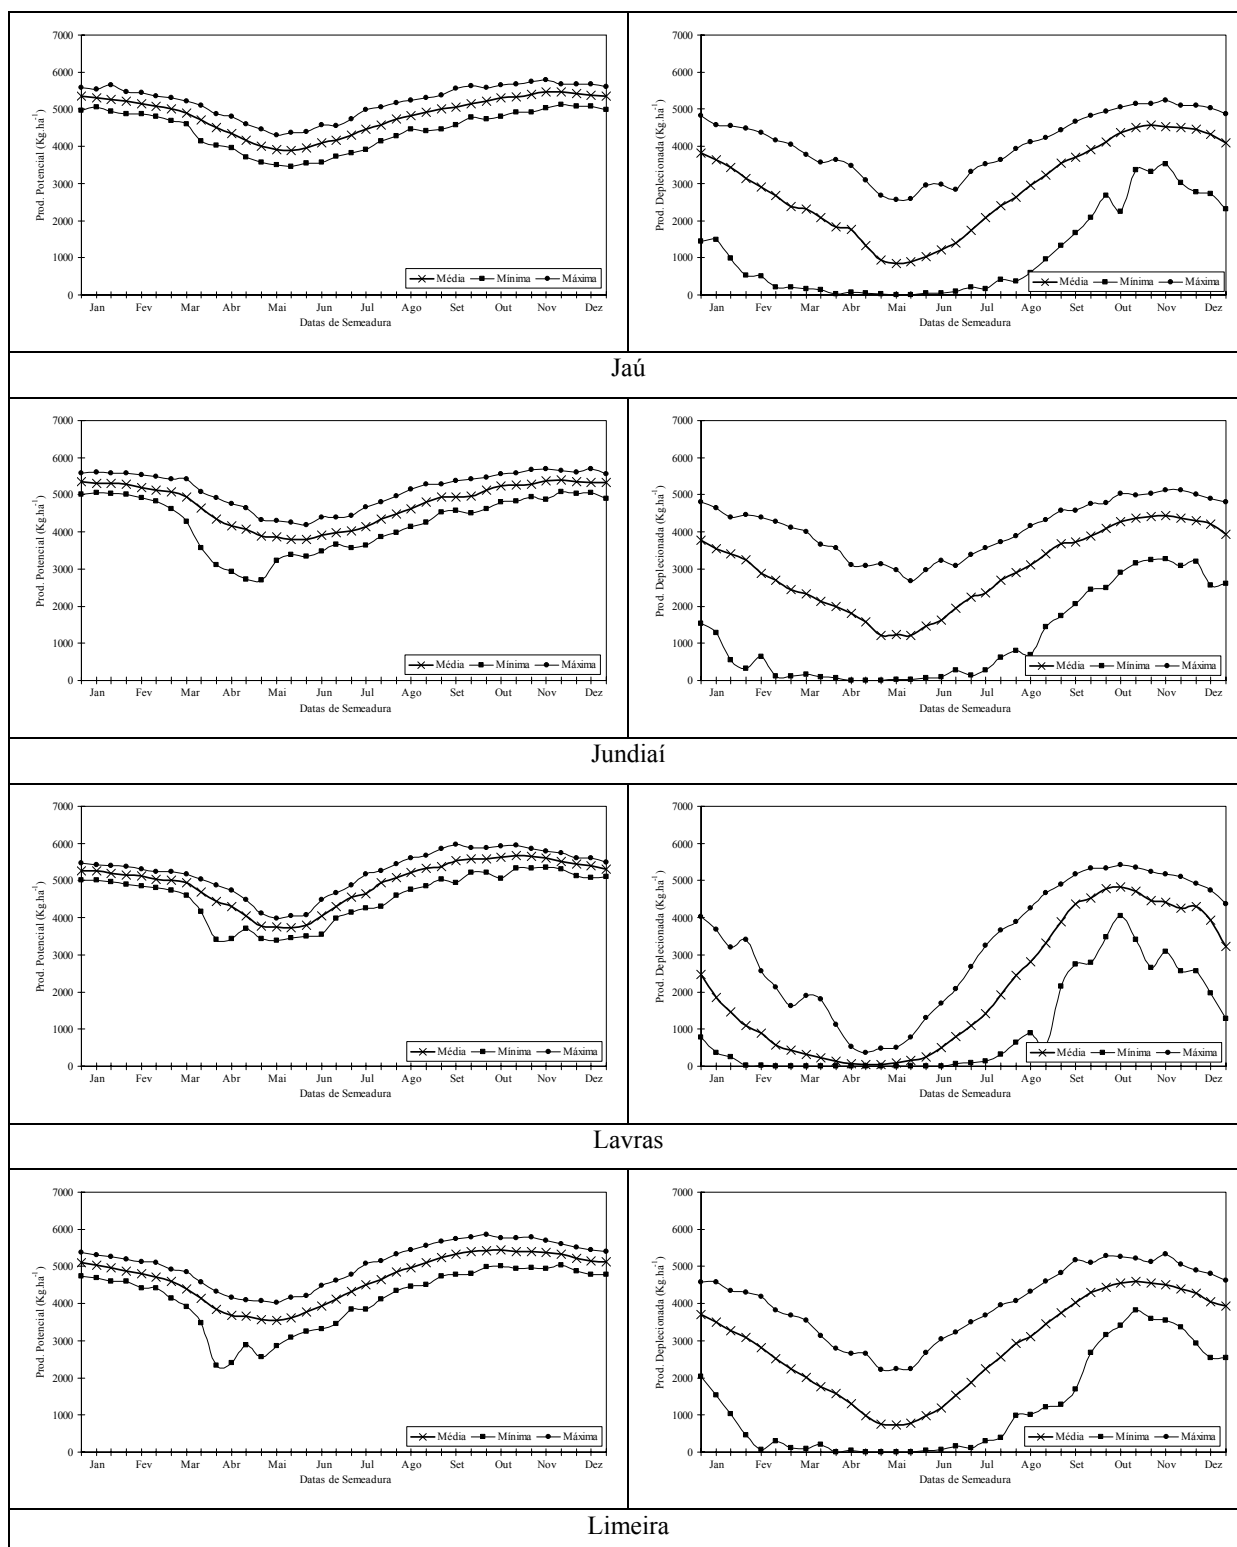


Figura 16 - Produtividade média, mínima e máxima durante as 36 datas de semeadura, obtidas através da simulação normal bivariada, valores referentes a 500 simulações (continuação)

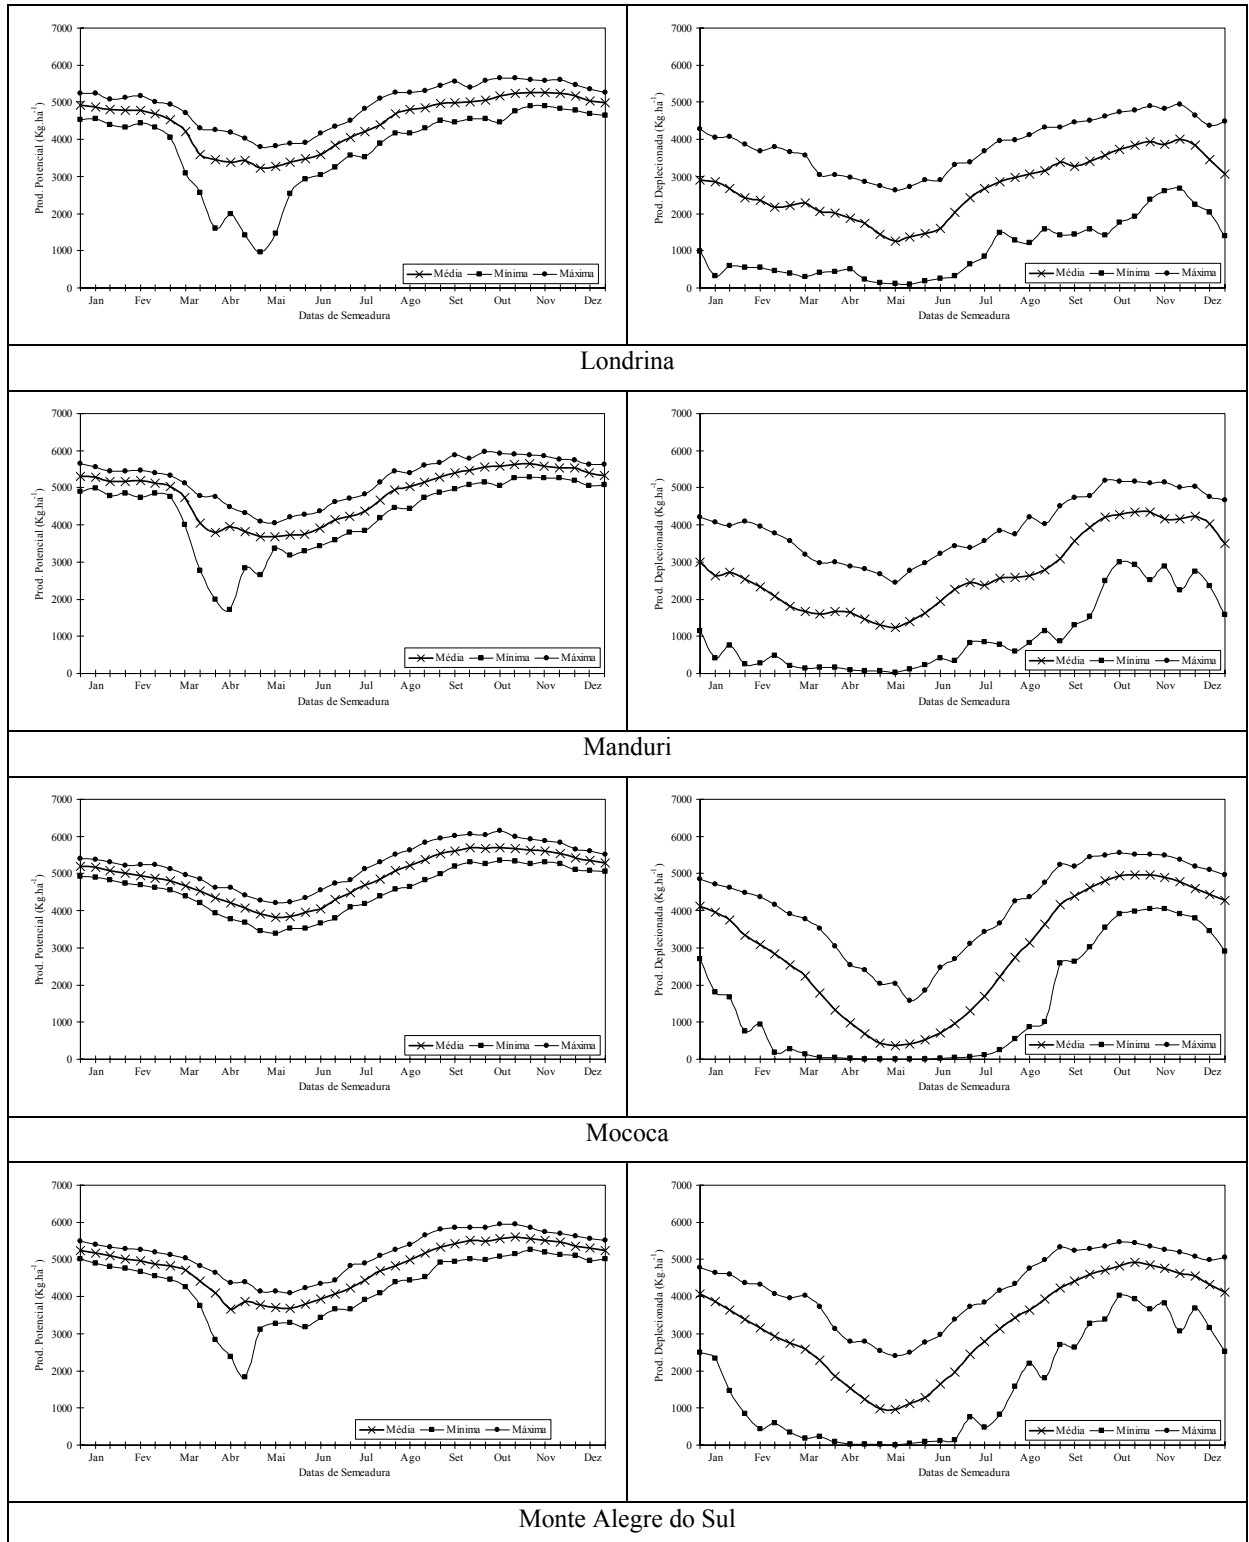


Figura 16 - Produtividade média, mínima e máxima durante as 36 datas de semeadura, obtidas através da simulação normal bivariada, valores referentes a 500 simulações (continuação)

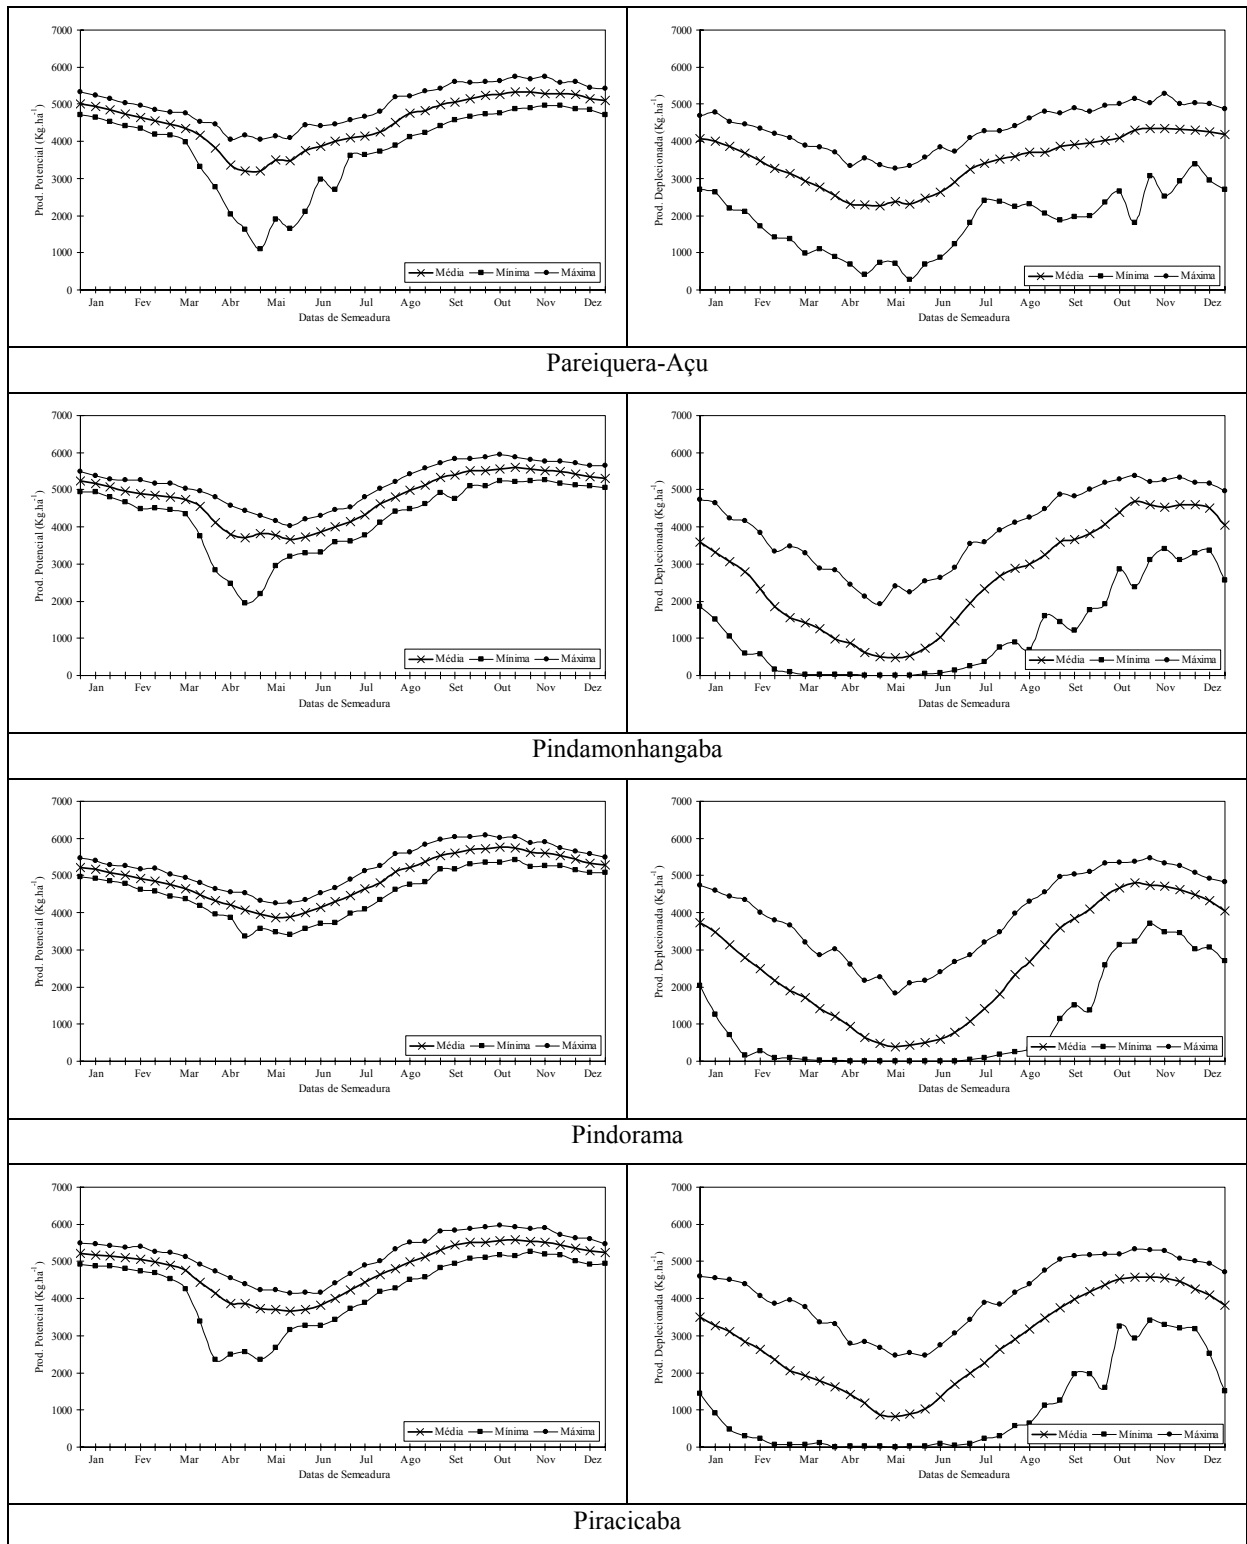


Figura 16 - Produtividade média, mínima e máxima durante as 36 datas de semeadura, obtidas através da simulação normal bivariada, valores referentes a 500 simulações (continuação)

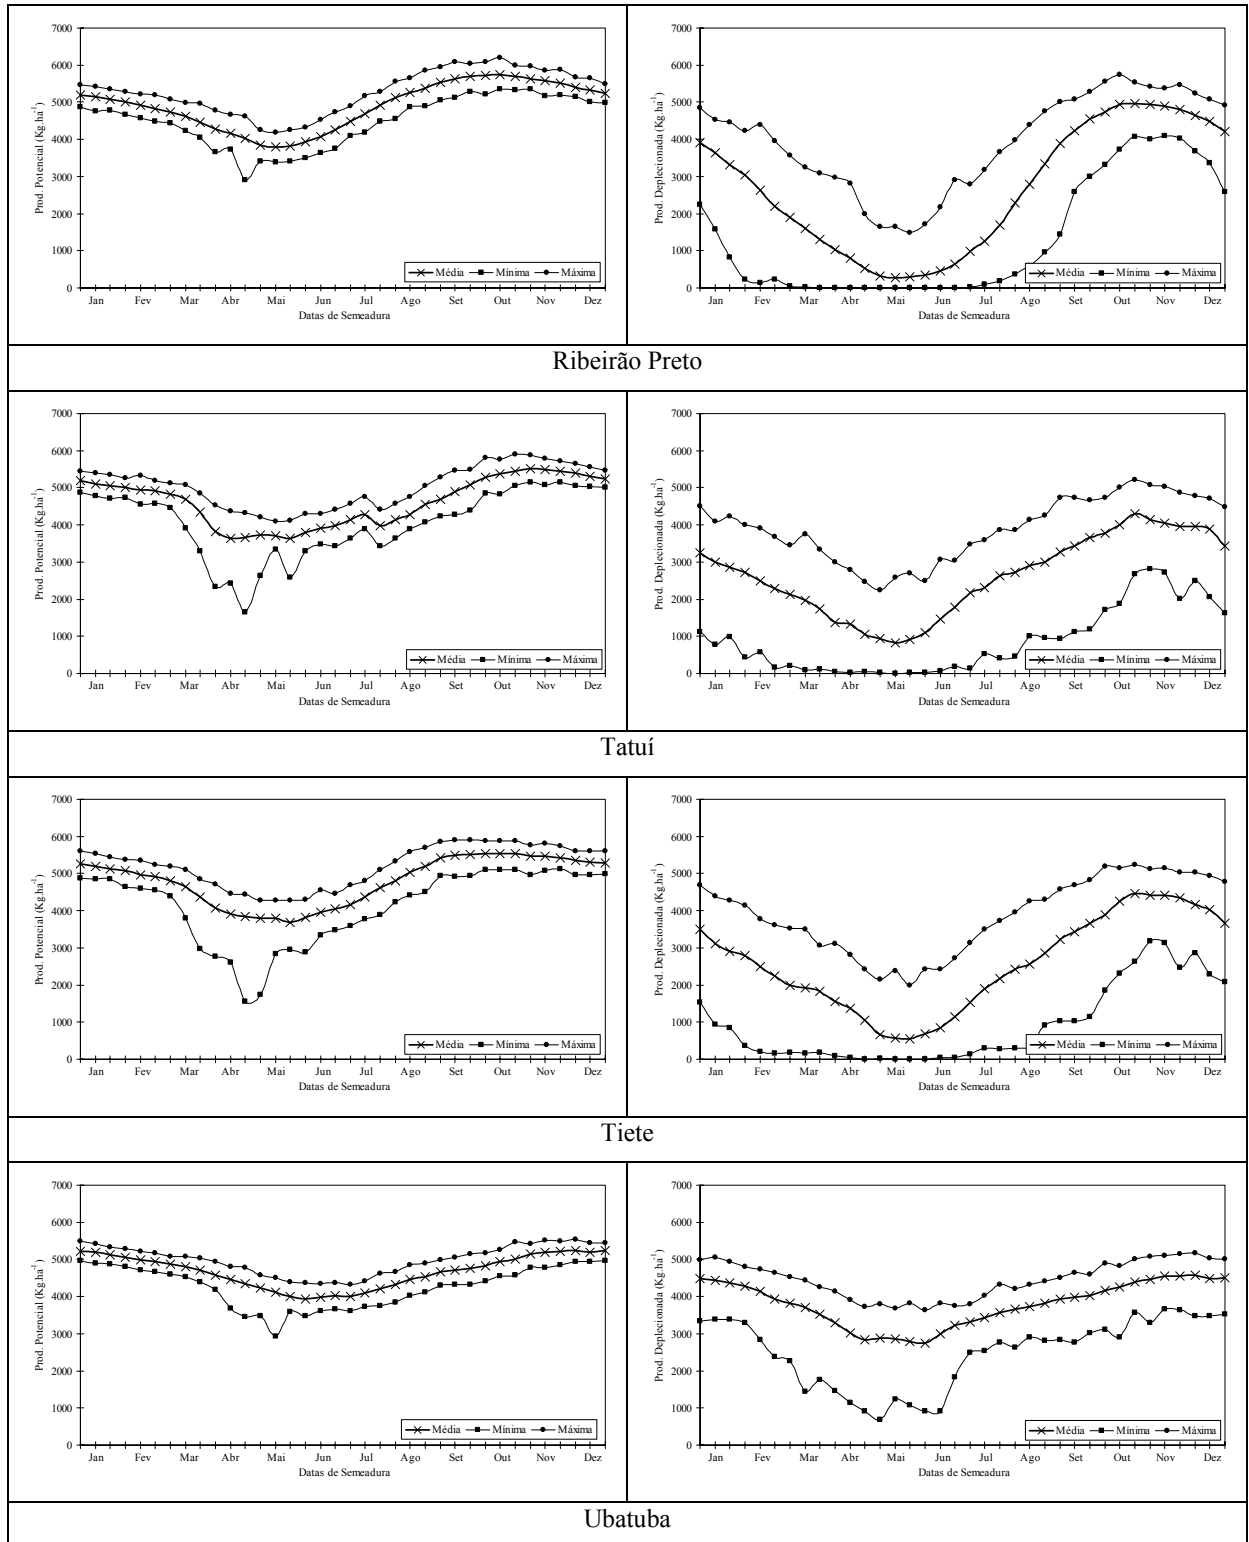


Figura 16 - Produtividade média, mínima e máxima durante as 36 datas de semeadura, obtidas através da simulação normal bivariada, valores referentes a 500 simulações (continuação)




Figura 16 - Produtividade média, mínima e máxima durante as 36 datas de semeadura, obtidas através da simulação normal bivariada, valores referentes a 500 simulações (final)

Com relação aos mapas de produtividade potencial e deplecionada (Figura 17), deve-se considerar que algumas localidades foram incluídas antes da geração dos mapas, sendo elas Atibaia, Amparo, Batatais, Campos do Jordão, Bragança Paulista, Poços de Caldas, Vinhedos e São Paulo. Atribuiu-se os valores de produtividade potencial e deplecionada para essas regiões como zero. O grande problema para essas regiões são as questões referentes a temperatura que, devido a altitude, são bastante reduzida. E no caso do capital São Paulo, não há possibilidade de cultivo, devido tratar-se de uma metrópole.

De maneira geral, percebe-se que as maiores produtividades, tanto as potencias quanto as deplecionadas, estão localizadas na região norte e sudoeste, para a maioria das épocas de semeadura. Comparando-se os resultados obtidos com as áreas de cultivo da cultura de soja (Figura 18), percebe-se que as condições de relevo e clima influenciaram o cultivo nas principais regiões com potencial produtivo.

Os mapas com as isolinhas de produtividade apresentam-se muito genéricos, podendo certamente indicar erros pela grande diversidade de ambientes que não foram contemplados no estudo. Somente com o estudo detalhado dos diversos ambientes é possível a confecção de um mapa com isolinhas de produtividades mais precisas. Mas em linhas gerais, algumas regiões apresentam potenciais para o cultivo (tratando-se apenas do aspecto climático). As regiões localizadas no centro do Estado em direção ao sudoeste apresentam as maiores potencialidades de cultivo. A região oeste do estado também possui um potencial elevado, como é observado na Figura 18.

Sobrepondo as Figuras 17 e 18, observa-se que o modelo é capaz de identificar as regiões aptas ao cultivo por estarem contempladas com os maiores valores de produtividade. Porém, há falha no aspecto referente aos locais onde a cultura torna-se inapta, isso devido tratar-se de um modelo agroclimatológico que não contempla as questões de relevo e solo. Dessa forma, pode-se utilizar o presente modelo para inferências de zoneamento para a cultura, mas devem ser observados outros aspectos para evitar equívocos grosseiros.

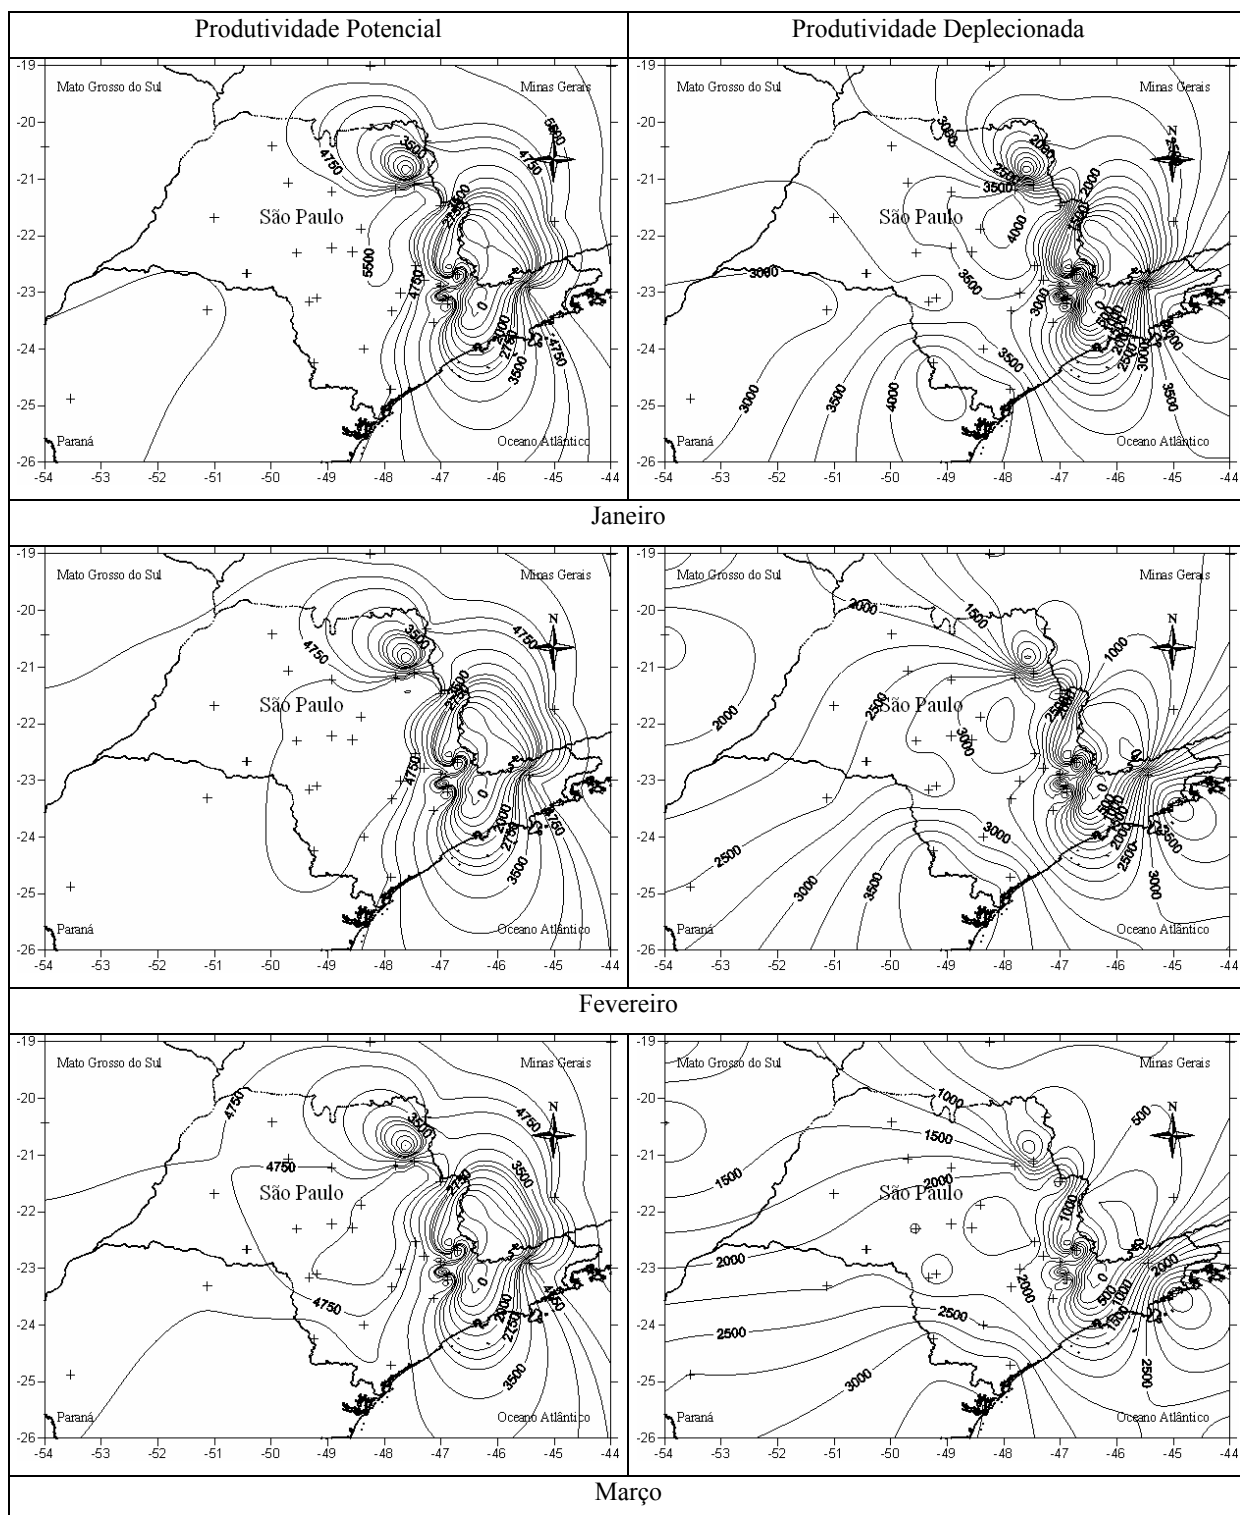


Figura 17 - Isolinhas de produtividade média potencial e deplecionada para as 25 localidades, obtidas através do método de interpolação de Krigagem (início)

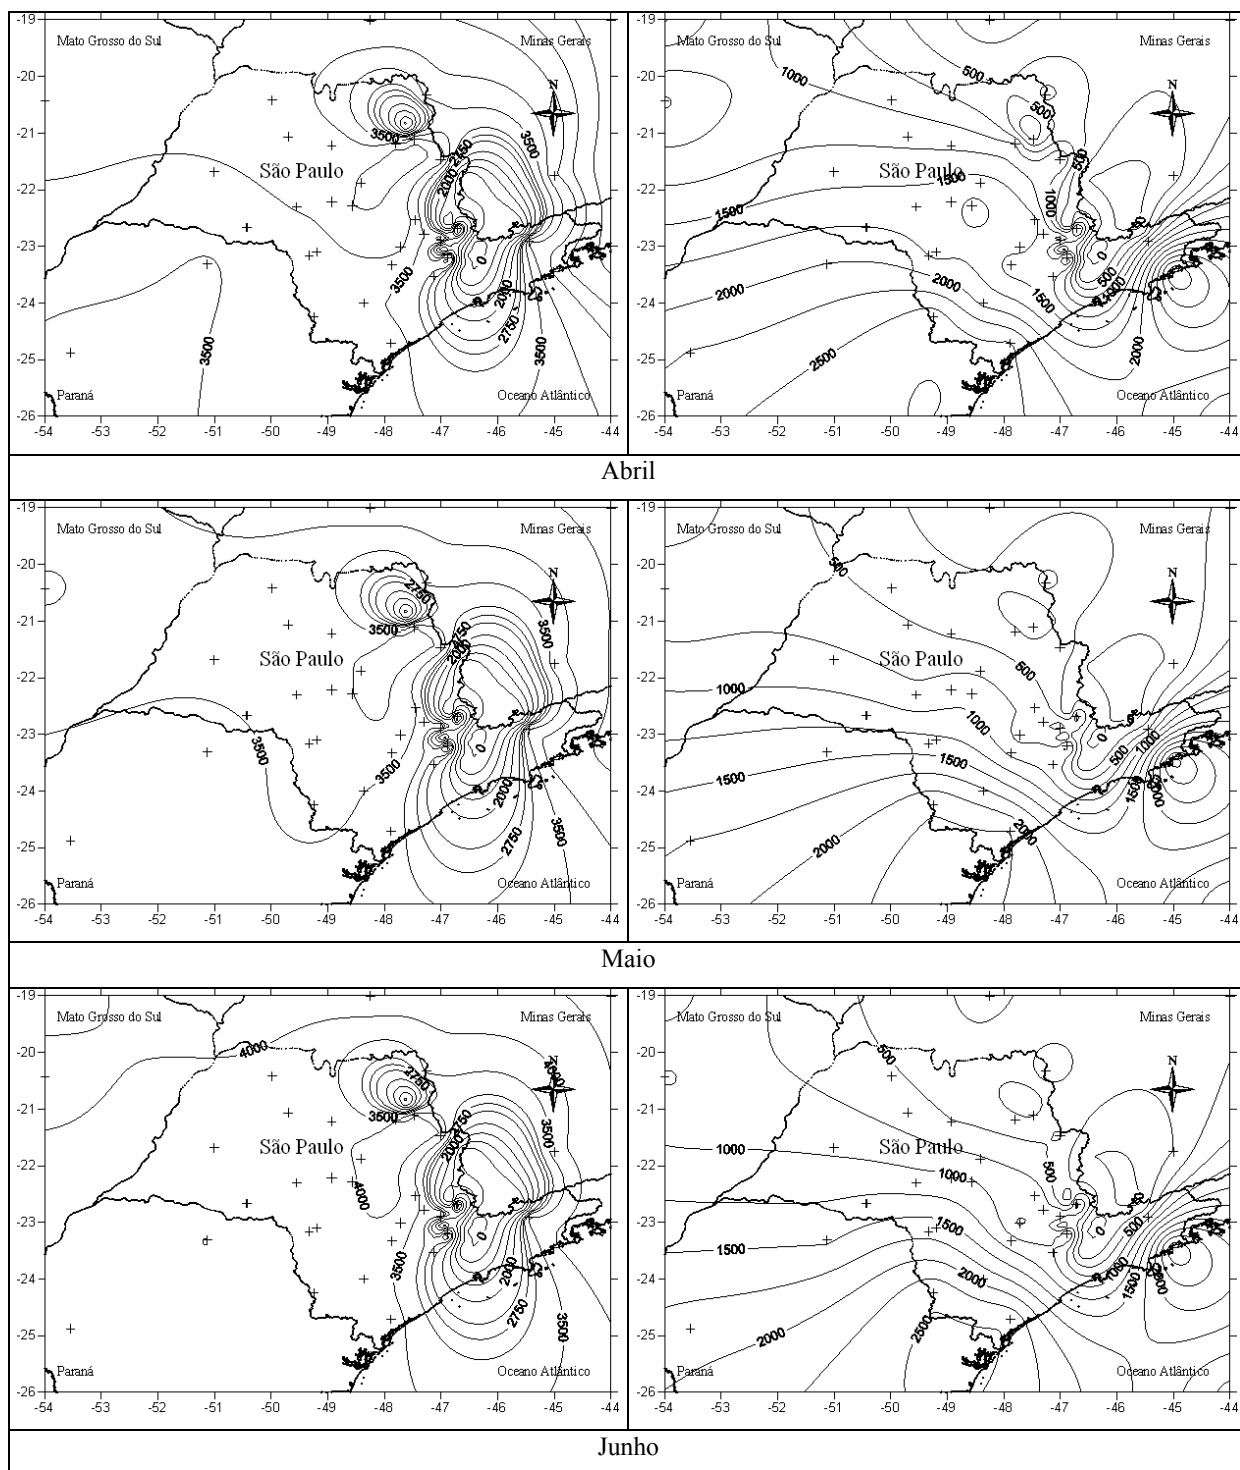


Figura 17 - Isolinhas de produtividade média potencial e deplecionista para as 25 localidades, obtidas através do método de interpolação de Krigagem (continuação)

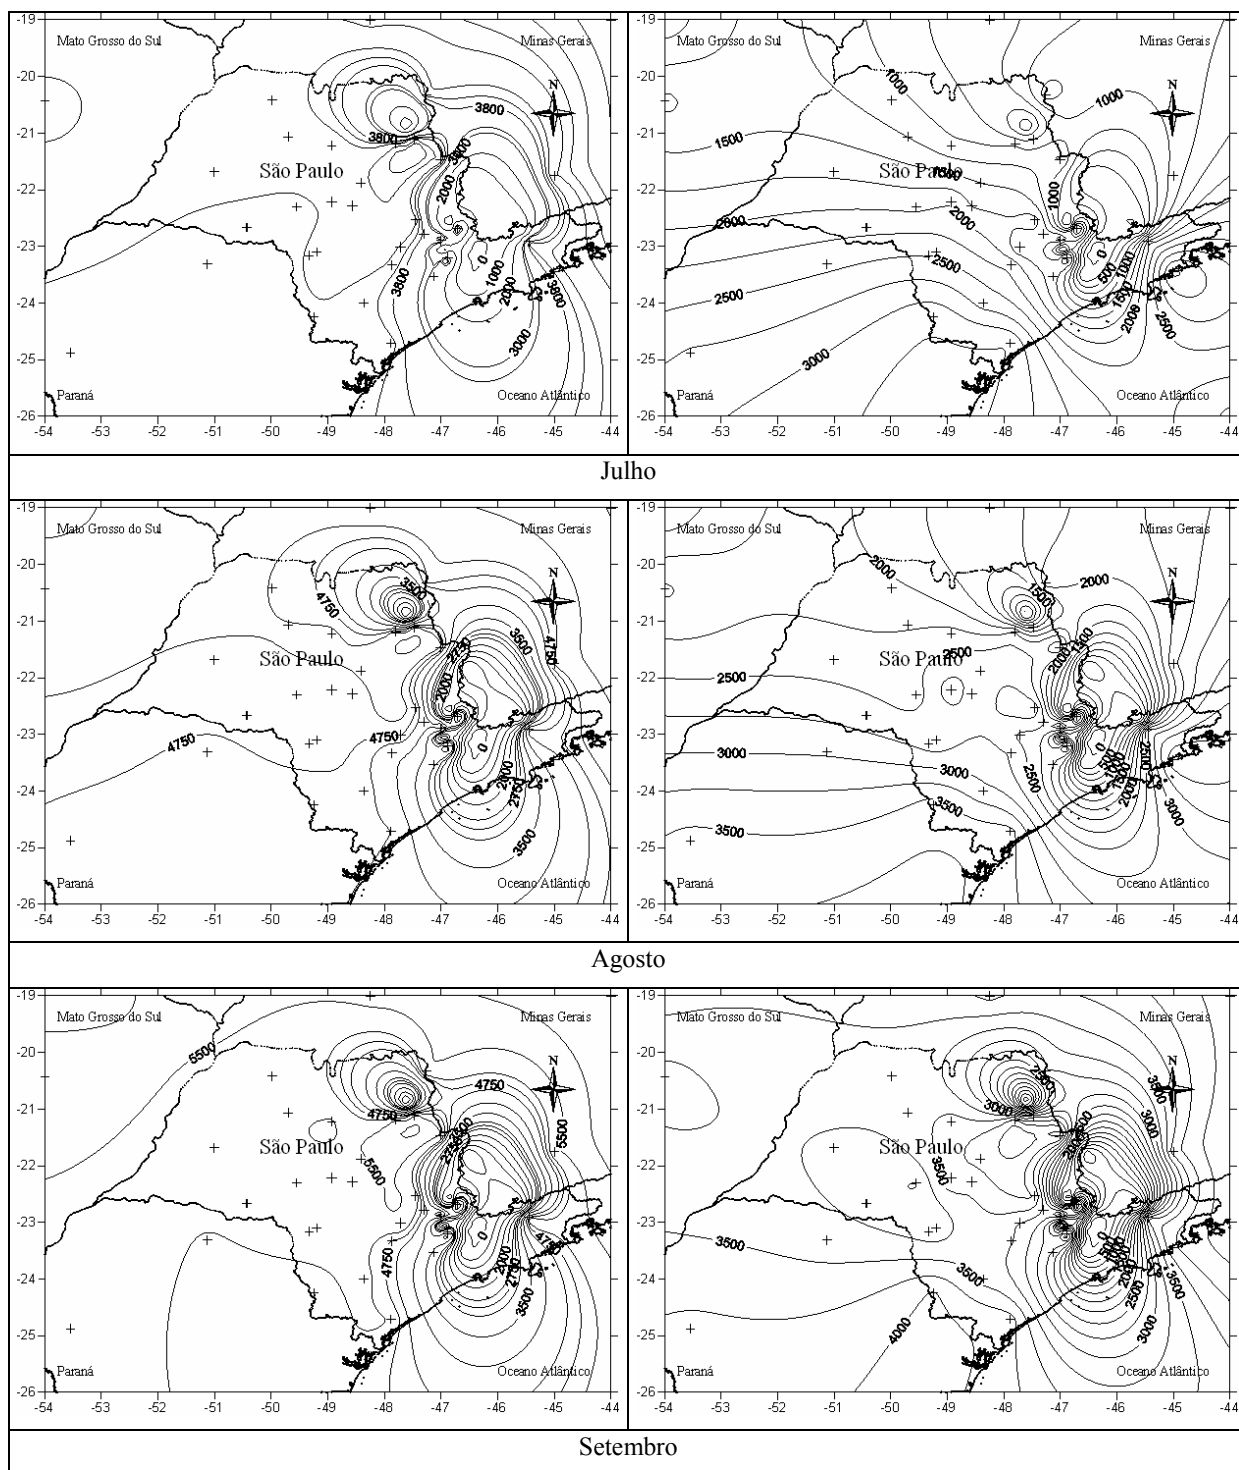


Figura 17 - Isolinas de produtividade média potencial e deplecional para as 25 localidades, obtidas através do método de interpolação de Krigagem (continuação)

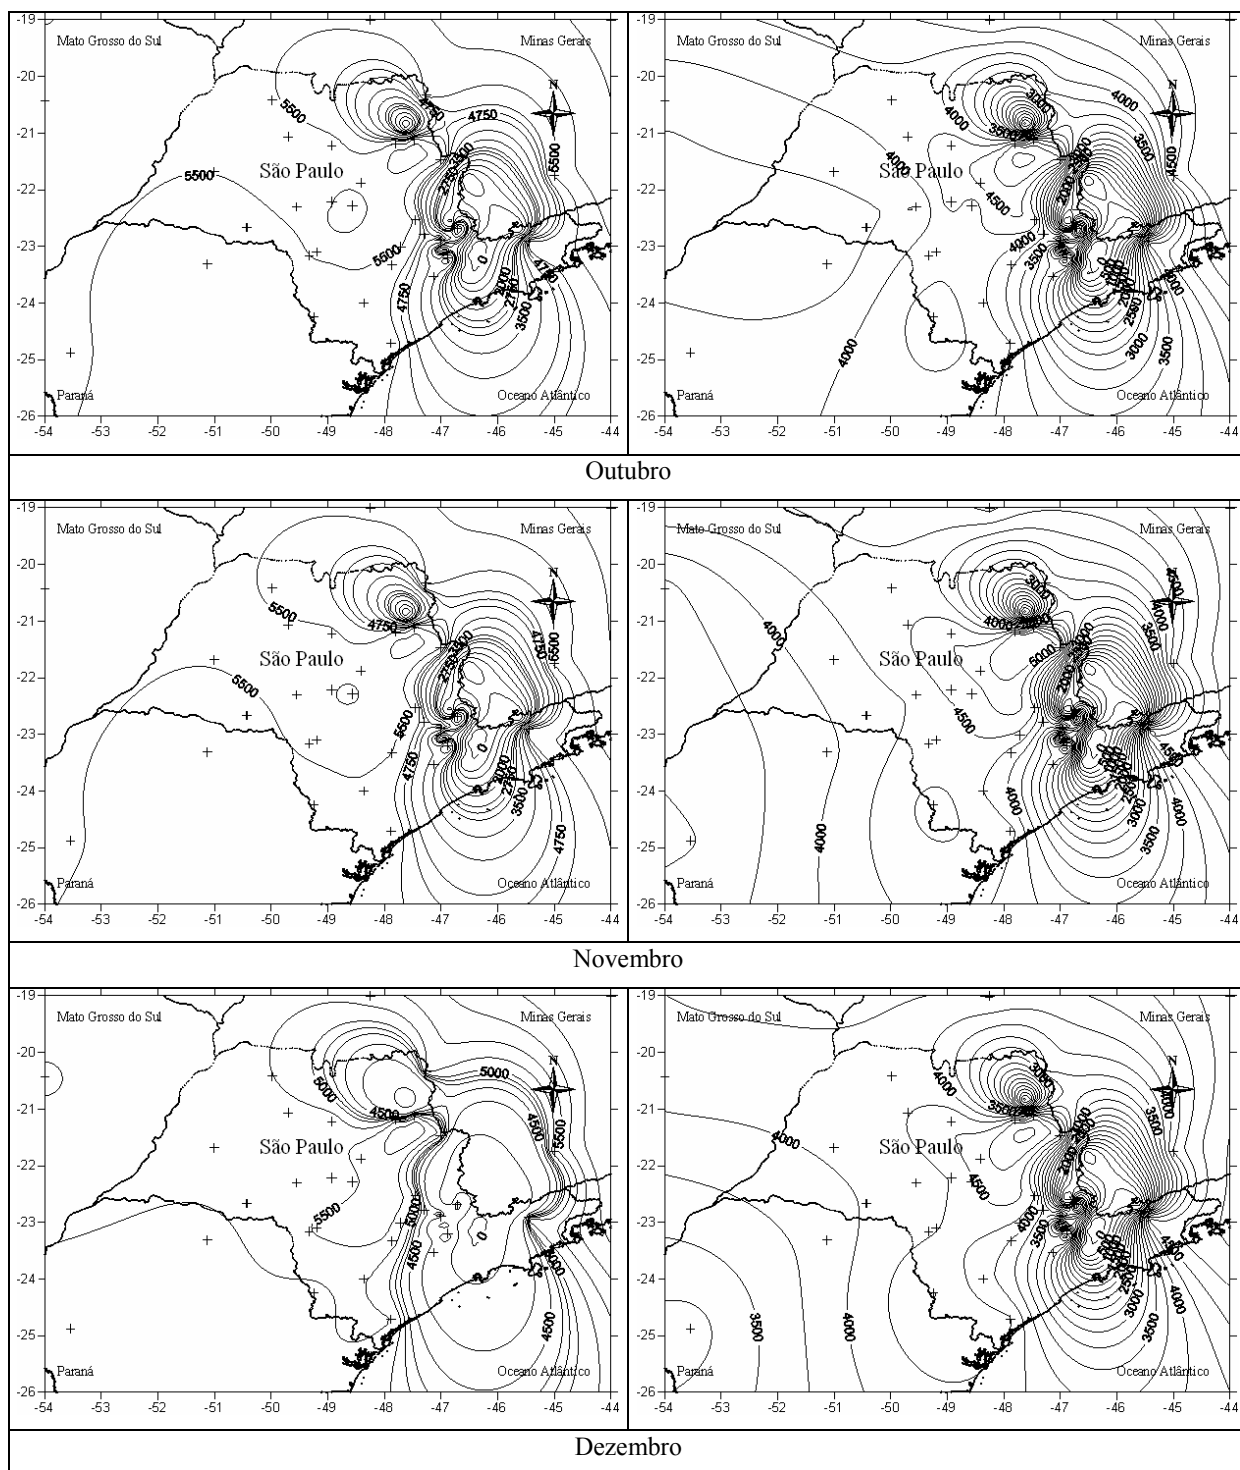


Figura 17 - Isolinhas de produtividade média potencial e deplecional para as 25 localidades, obtidas através do método de interpolação de Krigagem (final)

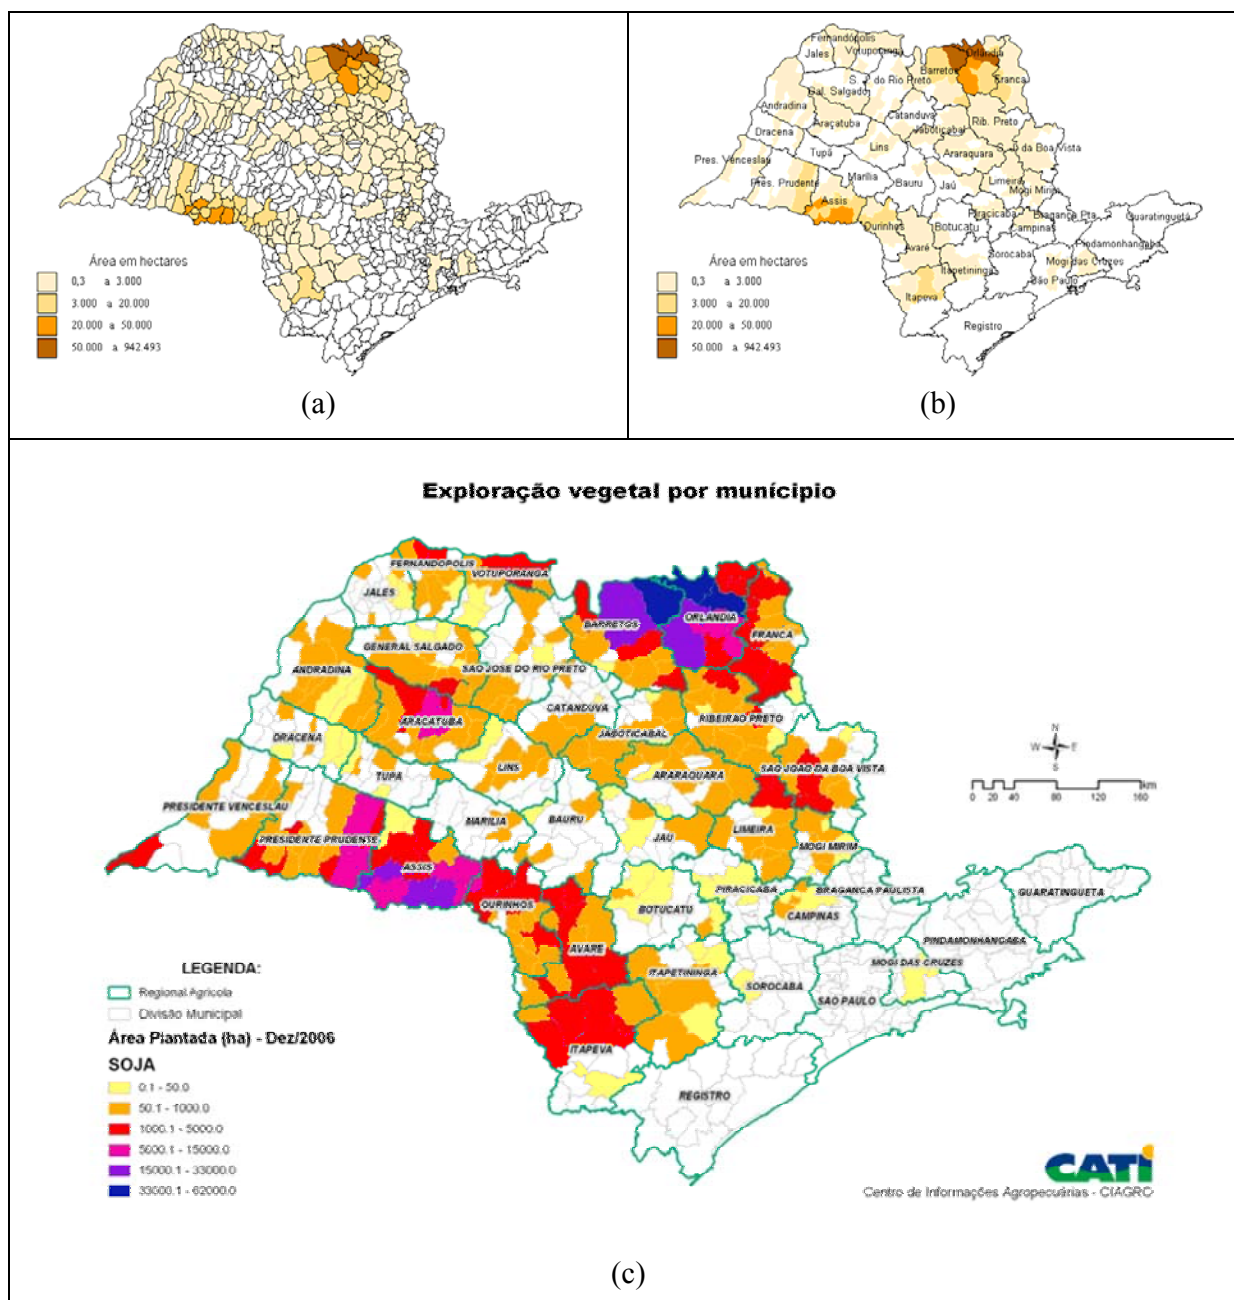


Figura 18 - Área cultivada com a cultura de soja por município em 1996 (a) e por região em 1996 (b) e 2006 (c), CATI, 2006

4.1 Considerações finais

De acordo com os objetivos do trabalho, os resultados obtidos podem ser resumidos no estabelecimento de uma metodologia para a previsão de parâmetros climáticos e sua aplicação na estimativa da produtividade de grãos de soja pelo emprego de um modelo fisiológico, que pode ser referido pela expressão Previsão de Safra.

Com relação aos dados utilizados, esses, originalmente, apresentaram problemas com valores que não correspondem a realidade, como por exemplo, várias temperaturas acima dos 60 °C ou ainda inferiores a -20 °C, valores de insolação menores que zero e maiores que o fotoperíodo. Quanto as chuvas, percebe-se que ao não se ter os dados de um determinado mês, houve a redação de zero no lugar, porém, verificou-se que isso ocorre no início de cada ano ou no final e foi realizado, provavelmente, para completar o período faltante. A organização dos bancos de dados, apesar de parecer um trabalho fácil e mecânico, exige muita atenção e despense um grande período de tempo. Como sugestão fica a integração dos bancos de dados existentes para facilitar trabalhos de pesquisa onde, através da permuta, poderá ser construído um banco de dados único e completo. A utilização desses dados deve ser controlada para fins científicos conduzidos por instituições (pesquisadores) sérias e competentes.

Dentre as maiores dificuldades encontradas para a execução desse trabalho, foi a escassa bibliografia básica (parâmetros morfológicos e fisiológicos) atualizada para as condições brasileiras. Além da utilização de parâmetros obtidos em outras condições, os dados, muitas vezes, estão defasados, fazendo com que a utilização de relações empíricas seja freqüente. A intensificação de experimentos a campo que objetivam a obtenção de parâmetros morfológicos e fisiológicos deve ser realizada. Apesar disso, deve-se observar a qualidade dos artigos científicos oriundos desses trabalhos, pois a finalidade principal de um artigo ou texto científico é a difusão de um conhecimento e, quando necessário da utilização dessas informações, elas devem estar claramente descritas sem que haja dúvidas na metodologia utilizada. O problema da cobrança por índices de produtividade científica (quantidade x qualidade) está aparecendo de maneira assustadora, pois os erros de redação de equações, unidades e formas de obtenção dos dados é muito mais freqüente do que atualmente imaginamos. Existiu a necessidade de refazer a maioria das equações apresentadas e utilizadas por outros autores, devido a erros de apresentação, além dos problemas de unidades, que também gerou muitos conflitos e demanda de tempo. Não que erros dessa natureza não estejam contemplados nessa tese, mas o cuidado nesse aspecto foi

redobrado. A pesquisa é como uma obra de arte, que deve ser produzida com calma e paciência, utilizando os mais diversos critérios para a avaliação da sua qualidade. Os redatores e consultores deveriam redobrar o tempo investido na melhoria da qualidade dos artigos e textos produzidos, assim haveria uma melhoria na ciência brasileira. Quem sabe a alteração nos parâmetros de mensuração dos índices de produtividades dos pesquisadores, a qualidade ao invés da quantidade seria mais interessante.

Indicações de pesquisas voltadas a fisiologia da produção da cultura de soja já foram abordadas anteriormente, e junto a isso, devem ser incentivadas linhas de pesquisa que interajam esse conhecimento como conceitos de simulação de dados (aspecto estocástico), metodologias de simulação nas mais diversas distribuições de probabilidade. Outro ponto que deve ser abordado é a auto-correlação entre os dias para questões da temperatura e principalmente da chuva, melhorando assim o balanço hídrico para aplicar a depleção na produtividade potencial. Outro ponto estatístico que deveria ser melhor abordado é a utilização de coeficiente de avaliação dos valores simulados, sendo que os que são utilizados comumente não possuem uma sensibilidade suficiente para detectar os diversos comportamentos dos processos de simulação. A verificação da normalidade bivariada através dos coeficientes de assimetria e curtose de Mardia devem ser realizadas. No presente trabalho, a verificação da normalidade bivariada não foi realizada devido a dificuldade no processamento de dados para uma amostra bivariada com 1000 pares. Anteriormente a isso, deveria ser estudado o número suficiente de simulações para melhorar a velocidade de processamento de dados.

Uma melhor representação dos resultados é realizada através da utilização de uma base de dados maior (maior número de estações). Nesse sentido, contemplaria exatamente o comportamento de locais com uma altitude superior a 1000m, que estariam com temperaturas médias desfavoráveis ao desenvolvimento da cultura. A incorporação de parâmetros de solo (capacidade de uso e manejo) faz-se interessante para evitar que ocorram erros de representação de produtividade em locais onde a cultura é inapta por deficiências climáticas e de solo. Na maioria das vezes, os softwares de interpolação dos dados não contemplam todas as diversidades ambientais por falta de dados de origem que representem tal situação. Então, um maior número de estações de dados é fundamental para evitar erros grotescos. A delimitação de localidades onde a cultura será naturalmente inapta, como por exemplo regiões com relevo inapto a mecanização,

serras, reservas ambientais deveriam ser mais fortemente contemplados, reforçando a idéia anterior.

A utilização da análise de agrupamento poderá sumarizar regiões com o mesmo comportamento em relação a produtividade potencial e deplecionada. Além desse estudo futuro, a determinação de áreas aptas (preferenciais, toleradas e inaptas) ao cultivo e a indicação das melhores épocas de semeadura, para as diversas regiões, poderão ser realizadas através desse estudo e incorporação de novos conhecimentos.

Questões referentes a riscos climáticos para quebra de safra poderão ser mais profundamente estudadas, incorporando questões referentes as mudanças climáticas, como questões referentes a La Niña e El Nino.

Dessa forma, o estudo realizado, juntamente com estudos futuros, poderá auxiliar em situações do planejamento e zoneamento agrícola, através da intensificação de pesquisas nas mais diversas áreas do conhecimento.

5 CONCLUSÕES

Considerando os resultados obtidos para as variáveis climáticas no Estado de São Paulo, Brasil, conclui-se que (i) para a variável temperatura mínima do ar, essa pode ser estudada usando as funções de distribuição de probabilidade normal, log-normal, gama e weibull, com ênfase para a distribuição normal; (ii) os dados de temperatura máxima do ar podem ser estudados usando as funções de distribuição de probabilidade log-normal, normal, weibull e gama, com ênfase às distribuições log-normal e normal; (iii) quanto as variáveis temperatura média do ar, insolação, radiação solar global e radiação fotossinteticamente ativa, as distribuições de probabilidade que melhor se ajustam são a normal, log-normal, gama e weibull; (iv) para a variável chuva, verifica-se que a distribuição que melhor se adapta aos dados é a log-normal e a distribuição de weibull; (v) quanto à variabilidade temporal e espacial, obteve-se que existe variabilidade, no tempo e no espaço, do tamanho de amostra (número de anos) para a estimativa da temperatura mínima, máxima e média do ar média mensal no Estado de São Paulo; (vi) o maior tamanho de amostra para a temperatura mínima é obtido nos meses de maio, junho e julho; (vii) o maior tamanho de amostra para temperatura máxima é obtido nos meses de agosto, setembro e outubro; (viii) para a temperatura média o maior tamanho de amostra deve ser realizado nos meses de julho, agosto, setembro, outubro; (ix) isso também ocorre para as variáveis insolação, radiação solar e radiação fotossinteticamente ativa; (x) além disso, a variabilidade amostral para essas variáveis depende do local e época do ano; (xi) a variação sazonal da precipitação pluvial apresenta três períodos estatisticamente definidos como seco, de transição e úmido; (xii) as maiores probabilidade de ocorrer precipitação pluvial ocorrem em dezembro, janeiro e fevereiro, e as menores probabilidade de chover ocorrem nos meses de junho, julho e agosto.

Considerando os resultados referentes a simulação de dados conclui-se que: (i) na escala diária, a simulação estocástica de dados com distribuição normal bivariada (radiação fotossinteticamente ativa e temperatura) é adequada e superior que as simulações individuais das variáveis (triangular assimétrica e normal a 1,96 desvios padrão da média) e (ii) quanto ao modelo de crescimento da cultura de soja, esse mostrou-se satisfatório na predição dos resultados de produtividade potencial e deplecionada no Estado de São Paulo.

REFERÊNCIAS

- ABRAMOWITZ, M.; STEGUN, I.A. **Handbook of mathematical functions with formulas, graphs, and mathematical tables**. Washington, D.C.: U.S. Government Printing Office, 987 p. 1972.
- ADAMS, D.B.; ADAMS, W.W.N. Photoprotection and other responses of plants to high light stress. **Annual Reviews Plant Physiology and Plant Molecular Biology**, Southampton, v.43, p.599-626, 1992.
- ADDISCOTT, T.M. Simulation modeling and soil behavior. **Geoderma**, Amsterdam, v.60, p.15-40, 1993.
- ALEXANDROV, V.A.; HOOGENBOOM, G. Vulnerability and adaptation assessments of agricultural crops under climate change in the southeastern USA. **Theoretical and Applied Climatology**, Wien, v.67, n.1/2, p.45-63, 2000.
- ALLEN, D.J.; ORT, D.R. Impacts of chilling temperatures on photosynthesis in warm-climate plants. **Trends Plant Science**, London, v.6, n.1, p.36-42, 2001.
- ALLEN, R.G. **Guidelines for computing crop water requirements**. Rome: FAO, 1998. (FAO Irrigation and Drainage Paper, 56).
- ALMEIDA, R.M.B. **Características climatológicas do regime de chuva em Minas Gerais**, 1995. 64p. Dissertação (Mestrado em Engenharia Agrícola), Universidade Federal de Viçosa, Viçosa, 1995.
- ANGELOCCI, L.R.; VILA NOVA, N.A. Variações da temperatura da água de um pequeno lago artificial ao longo de um ano em Piracicaba - SP. **Scientia Agrícola**, Piracicaba, v.52, n.3, p.13-18, 1995.
- ARRUDA, F.B. MASCARENHAS, H.A.A.; VIEIRA, S.R., **Efeito hídrico na produção de soja: Análise**. Campinas. Instituto agrônomo. 1978. 24p. (Boletim Técnico).
- ASSIS, F.N. Probabilidades de ocorrência de dias sem chuva e chuvosos em Pelotas, RS. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.2, p.87-92, 1994.
- ASSIS, J. P.; DOURADO NETO, D., REICHARDT, K.; MANFRON, P.; MARTIN, T.N.; BONNECARRÈRE, R.A.G. Dados climáticos simulados e produtividade potencial do milho. **Pesquisa Agropecuária Brasileira**, Brasília, v.41, n.5, p.731-737, 2006.
- ASSIS, J.P.; DOURADO NETO, D.; MANFRON, P. A.; MARTIN, T.N.; SPAROVEK, G.; TIMM, L.C.; Ajustes de séries históricas de temperatura e radiação solar global diária às funções de densidade de probabilidade normal e log normal em Piracicaba, SP. **Revista Brasileira de Agrometeorologia**, Piracicaba, v.12, n.1, p.113-121, 2004.
- ASSUNÇÃO, H.F. **Relações entre radiação fotossinteticamente ativa e a radiação solar global em Piracicaba, SP**. Piracicaba, 1994. 41p. Dissertação (Mestrado em Física do Ambiente

Agrícola) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 1994.

BAIER, W. Note on the terminology of crop-weather models. **Agricultural Meteorology**, Amsterdã, v.20, n.2, p.137-145, 1979.

BARROS, A.H.C. **Análise de crescimento, do desenvolvimento e da produtividade da cultura da cultura do milho (*Zea mays* L.): Experimentos e modelos**. 1998. 85p. Dissertação de (Mestrado em Fitotecnia) – Universidade Federal de Viçosa, Viçosa, 1998.

BATCHELOR, W.D.; JONES, J. W.; BOOTE, K. J.; PINNSCHMIDT, H.O. Extending the use of crop models to study pest damage. **Transactions of the American Society of Agricultural Engineers**, St. Joseph, v.36, n.2, p.551-558. 1993.

BAUER, H.; MARTHA, P.; KIRCHER-HEISS, B. The CO₂ compensation point of C3 plants – a re-examination. II. Intraspecific variability. **Zeitschrift Pflanzenphysiologie**, Stuttgart, n.109, p.143-154, 1983.

BEEG, J.E.; TURNER, N.C. Crop water deficits. **Advances in Agronomy**, New York, v.28, p.161-217, 1976.

BERGAMASCHI, H., Desenvolvimento de déficit hídrico em culturas. In: BERGAMASCHI, H. (Coord.). **Agrometeorologia aplicada à irrigação**. Porto Alegre, Editora da Universidade UFRGS. 1992, p.25-35.

BERLATO M.A.; BERGAMASCHI, H. Consumo de água de soja. I. Evaporação estacional em ótimas condições de disponibilidade de água no solo. In: SEMINÁRIO NACIONAL DE PESQUISA DE SOJA, 1., 1978, Londrina. **Anais...** Londrina: Embrapa-CNPSo, 1979. v.1, p.53-58.

BERLATO, M.A. **Modelo de relação entre o rendimento de grãos de soja e o déficit hídrico para o Estado do Rio Grande do Sul**. 1987. 93p. Tese (Doutorado em Meteorologia), Curso de Pós-graduação em Meteorologia, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1987.

BEUERLEIN, J.E.; PENDLETON, J.W. Photosynthetic rates and light saturation curves of individual soybean leaves under field condition. **Crop Science**, Madison, v.11, n.2, p.217-219, 1971.

BLANCO, F.F.; SENTELHAS, P.C. Coeficientes da equação de Angström-PreScott para estimativa da insolação para Piracicaba, SP. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.10, n.2, p.295-300, 2002.

BOCK, R.D. **Multivariate statistical methods in behavior research**. Chicago: MacGraw-Hill, 1975. 623p.

BOERMA, H. R.; ASHLEY, D. A. Irrigation, row spacing, and genotype effects on late and ultralate planted soybeans. **Agronomy Journal**, Madison, v. 74, n. 6, p. 995-999, 1982.

- BONATO, E.R.; VELLO, N.A. Aspectos genéticos do tempo para o florescimento em variantes naturais de soja. **Pesquisa Agropecuária Brasileira**, Brasília, v.34, n.6, p.989-993, 1999.
- BOOKER, F.L.; REID, C.D.; BRUNSCHON-HARTI, S.; FISCUS, E.L.; MILLER, J.E. Photosynthesis and photorespiration in soybean [*Glycine max* (L.) Merr.] Chronically exposed to elevated carbon dioxide and ozone. **Journal of Experimental Botany**, Berlin, v.48, n.315, p.1843-1852, Oct, 1997.
- BOOTE, K. J.; JONES, J. W.; PICKERING, N. B. Potential uses and limitations of crop models. **Agronomy Journal**, Madison, v.88, p.704–716, 1996.
- BOOTE, K.J.; JONES, J.W.; PICKERING, N.B. The CROPGRO model for grain legumes. In: TSUJI, G.; HOOGENBOOM, G. THORNTON, P.K. (Ed.) **Understanding options for agricultural production**. Dordrecht, the Netherlands: Kluwer Academic Publ. 1998, p.99-128.
- BORTHWICK, H.A.; PARKER, M.W., Influence of photoperiods upon the differentiation of meristems and the blossoming of Biloxi soybeans. **Botany Gazette**, Chicago, n.99, p.825–839, 1938.
- BOTELHO, V.A.V.A.; MORAIS, A.R. Estimativas dos parâmetros da distribuição gama de dados pluviométricos do Município de Lavras, Estado de Minas Gerais. **Ciência e Agrotecnologia**, Lavras, v.23, p.697-706, 1999.
- BOX, G.E.P; MULLER, M.E. A note on the generation of random normal deviates. **The Annals of Mathematical Statistics**, Baltimore, v.29, p.610-611, 1958.
- BRESSAN, G. **Modelagem e simulação de sistemas computacionais**. São Paulo: EDUSP/ IME, 2002. 12 p. (Notas de Aula).
- BUNCE, J.A.; ZISKA, L.H., Responses of respiration to increase in carbon dioxide concentration and temperature in three soybean cultivars. **Annal of Botanical**, Jülich, v.77, p.507–514, 1996.
- BURIOL, G.A.; ESTEFANEL, V.; ANDRIOLO, J.L.; MATZENAUER, R.; TAZZO, I.F. Disponibilidade de radiação solar para o cultivo do tomateiro durante o inverno no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Gaúcha**, Porto Alegre, v.6, p.113-120, 2000a.
- BURIOL, G.A.; HELDWEIN, A.B.; ESTEFANEL, V.; MATZENAUER, R.; MARCON, I.A. Condições térmicas para o cultivo do pepineiro na região do baixo vale do Taquari: 2. Temperatura máxima e soma térmica. **Pesquisa Agropecuária Gaúcha**, Porto Alegre, v.6, p.215-223, 2000b.
- BURIOL, G.A.; HELDWEIN, A.B.; ESTEFANEL, V.; MATZENAUER, R.; MARCON, I.A. Probabilidade de ocorrência de valores de radiação solar prejudiciais ao cultivo do pepineiro na região do baixo vale do Taquari, RS. **Pesquisa Agropecuária Gaúcha**, Porto Alegre, v.7, p.97-104, 2001.

CAEMMERER, VON S.; EVANS, J.R. Determination of the average partial pressure of CO₂ in chloroplasts from leaves of several C₃ plants. **Australian Journal of Plant Physiology**, Melburn, n.18, 287-305, 1991.

CAIXETA FILHO, J.V. **Pesquisa operacional**: Técnicas de otimização aplicadas a sistemas agroindustriais. São Paulo: Atlas, 2001. 171p.

CÂMARA, G.M.S. (Ed.) **Soja: tecnologia da produção II**. G.M.S. Câmara, Piracicaba, 2000, 450 p.

CÂMARA, G.M.S. **Efeito do fotoperíodo e da temperatura no crescimento, florescimento e maturação de cultivares de soja (*Glycine max* (L.) Merrill)**. 1991. 266p. Tese (Doctor Science) - Universidade Federal de Viçosa, Viçosa, 1991.

CÂMARA, G.M.S.; HEIFFIG, L.S. Fisiologia, ambiente e rendimento da cultura de soja. In.: CÂMARA, G.M.S. **Tecnologia da produção II**. Esalq/USP, Piracicaba, 120 p. 2000.

CAMARGO, A.P.; SENTELHAS, P.C. 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, n.1, p.89-97, 1997.

CAMARGO, M.B.P **Exigências bioclimáticas e estimativa da produtividade para quatro cultivares de soja no estado de São Paulo**. 1984. 96p. Dissertação (Mestrado em Física do ambiente agrícola). Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 1984.

CAMARGO, M.B.P.; PEDRO JÚNIOR, M.J.; ALFONSI, R.R.; ORTOLANI, A.A.; BRUNINI, O. Probabilidades de ocorrência de temperaturas mínimas absolutas mensais e anual no Estado de São Paulo. **Bragantia**, Campinas, v.52, n.2, p.161-168, 1993.

CAMPOS, H. **Estatística não paramétrica**. 4^a ed. Piracicaba: ESALQ/USP, 1983. 349 p.

CARBONE, G.J.; MEARNES, L.O.; MAVROMATIS, T.; SADLER, E.J.; STOOKSBURY, D. Evaluating CROPGRO-Soybean performance for use in climate impact studies. **Agronomy Journal**, Madison, v.95, p.537-544, 2003.

CARGNELUTTI FILHO, A.; MATZENAUER, R.; MALUF, J.R.T.. Variabilidade temporal e espacial do tamanho de amostra da temperatura mínima do ar no Rio Grande do Sul, Brasil. **Ciência Rural**, Santa Maria, v.36, n.4, p.1156-1163, 2006.

CARGNELUTTI FILHO, R.; MATZENAUER, R.; TRINDADE, J.K.; Ajustes de funções de distribuição de probabilidade à radiação solar global no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, Brasília, v.39, n.12, p.1157-1166, 2004.

CASTRO, R. **Distribuição probabilística da frequência de precipitação na região de Botucatu-SP**. 1996. 101p. Dissertação (Mestrado em Estatística) - Universidade Estadual Paulista, “Julia de Mesquita Filho”, Botucatu, 1996.

- CATALUNHA, M.J.; SEDIYAMA, G.C.; LEAL, B.G.; SOARES, C.P.B.; RIBEIRO, A. Aplicação de cinco funções densidade de probabilidade a séries de precipitação pluvial no Estado de Minas Gerais. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.10, n.1, p.153-162, 2002.
- COBER, E.R., D.W. STEWART, VOLDENG, H.D. Photoperiod and temperature responses in early-maturing near-isogenic soy-bean lines. **Crop Science**, Madison, v.41, p.721-727, 2001.
- COELHO, A. M.; PAULO FILHO, I.A.; CRUZ, J.C. Rendimento do milho no Brasil: chegamos ao máximo? **Informações Agrônomicas**. Piracicaba, n.101, p. 12, 2003.
- COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). Soja, Brasil – Série histórica de produtividade (1990 – 2005). Disponível em: <<http://www.conab.gov.br/download/safra/SojaSerieHist.xls>>. Acesso em: 5 jul. 2005.
- COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). Soja, Brasil – Série histórica de produtividade (1990 – 2005). Disponível em: <<http://www.conab.gov.br/download/safra/SojaSerieHist.xls>>. Acesso em: 5 jul. 2005.
- COOPER, R.L. A delayed flowering barrier to higher soybean yields. **Field Crops Research**, Amsterdã, v.82, p.27-35, 2003.
- COORDENADORIA DE ASSISTÊNCIA TÉCNICA INTEGRADA (CATI). Mapas Agrícolas. Disponível em: <http://www.cati.sp.gov.br/novacati/servicos/mapa/culturas/Mapas_Agricolas2006/Mapas_PDF/Soja.pdf>
- COSTA, L.C. Modelagem e simulação em agrometeorologia. In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA 10. 1997. Piracicaba. **Anais...** Piracicaba: SBA, 1997. p.3-6.
- COX, P.M.; BETTS, R.A.; JONES, C.D.; SPALL, S.A.; TOTTERDELL, I.J. Acceleration of global warming due to carbon-cycle feedbacks in a coupled climate model. **Nature**, London, v.408, p.184-187, 2000.
- CURL, R.L. Stochastic models of cavern development. **Bulletin of the Geological Society of America**, Colorado, n.70, p.1803-1810, 1959.
- De WIT, C.T. **Simulation for assimilation, respiration, and transpiration of crops**, Wageningen: A Halsted Press book. John Wiley, 1978. 140p.
- DINIZ, G.B. BERLATO, M.A.; CLARCK, R.T.; FONTANNA, D.C. Identificação de regiões homogêneas de temperaturas máxima e mínima do Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.11, n.2, p.303-312, 2003.
- DOORENBOS, J.; KASSAM, A. H. **Yield response to water**. Food and Agriculture Organization of the United Nations, Rome: 1979. 193p. (FAO-Irrigation and Drainage Paper, 33)

DOORENBOS, J.; KASSAM, A.H. **Efeito da água no rendimento das culturas**. Trad. de GHEYI, H. Campina Grande: UFPB, 1994. 306p. (Estudos FAO: Irrigação e Drenagem, 33).

DORNHOFF, G.M.; SHIBLES, R.M. Varietal differences in net photosynthesis of soybean leaves. **Crop Science**, Madison, v.10, p.42-45, 1970.

DOURADO NETO, D. **Modelos fitotécnicos referentes à cultura do milho**. 1999. 229p. Tese (Livre-Docência) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 1999.

DOURADO NETO, D. TERUEL, D.A.; REICHARDT, K.; NIELSEN, D.R.; FRIZZONE, J.A.; BACCHI, O.O.S.. Principles of crop modeling and simulation. I. Uses of mathematical models in agriculture science. **Scientia Agricola**, Piracicaba, v.55, p.46-50, 1998.

DOURADO NETO, D.; ASSIS, J.P.; TIMM, L.C.; MANFRON, P.A.; SPAROVEK, G. MARTIN, T.N. Ajustes de modelos de distribuição de probabilidade a séries históricas de precipitação pluvial diária em Piracicaba, SP. **Revista Brasileira de Agrometeorologia**, Piracicaba, v.13, n.2, p.273-283, 2005.

DRIESSEN, P.M.; KONIJN, N.T. **Land-use systems analysis**. Wageningen: Wageningen Agricultural University, 1992. 230p.

DYBING, C.D. Soybean flower production as related to plant growth and seed yield. **Crop Science**, Madison, v.34, n.2, p.489-497, 1994.

EMBRAPA - http://www.cnpso.embrapa.br/index.php?op_page=195ecod_pai=87 Acessado em 12 jul. 2005.

ESTEFANEL, V. SCHEIDER, F.M.; BURIOL, G.A. Probabilidade de ocorrência de temperaturas máximas do ar prejudiciais aos cultivos agrícolas em Santa Maria, RS. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.2, p.57-63, 1994.

ESTEFANEL, V.; BURIOL, G.A.; SCHNEIDER, F.M. Estimativa da duração da temperatura do ar acima de determinados níveis térmicos em Santa Maria, RS. **Revista Brasileira de Agrometeorologia**, Santa Maria v.3, p.121-127, 1995.

ETHERIDGE, D.M.; STEELE L.P.; LANGENFELDS, R.L.; FRANCEY, R.J.; BARNOLA, J.M.; MORGAN, V.I. Natural and anthropogenic changes in atmospheric CO₂ over the last 1000 years from air in Antarctic ice and firn. **Journal Geophysical Research**, Washington, v.101, p.4115-4128, 1996.

EVANS, L.T. **Crop evolution, adaptation and yield**. Cambridge: Cambridge University Press, 1993, 500p.

EVERITT, B.S.; DUNN, G. **Applied multivariate analysis**. London: Edward Arnold, 1991. 400p.

FISHER, J.E. The effect of short days on fruit set as distinct from flower formation in soybeans. **Canadian Journal of Botanic**. Ottawa, n.41, p.871-873, 1963.

FONSECA, V.O.; ALBUQUERQUE, J.A.S. Estimativa dos parâmetros da distribuição gama de probabilidades para totais de precipitação em uma região de Pelotas, RS. **Pesquisa Agropecuária Brasileira**, Brasília, v.13, n.3. p. 47-58, 1978.

FRIZZONE, J.A.; RETTORE, P.R.; PEREIRA, G.T. Análise de distribuição das precipitações em períodos de 5 a 10 dias na região de Pereira Barreto, SP, utilizando a distribuição gama incompleta. **Irrigação e Tecnologia Moderna**, Brasília, v.22, n.1, p.2-4, 1985.

FRIZZONE, J.A.; SOLANI, R.; COELHO, R.D.; DOURADO NETO, D. Linear programming model to optimize the water resource use in irrigation projects: an application to the senator Nilo Coelho project. **Scientia Agrícola**, Piracicaba, v.54, Número Especial, p.136-148, 1997.

GARNER, W.W.; ALLARD, H A. Photoperiodic response of soybeans in relation to temperature and other environmental factors. **Journal of Agricultural Research**, Washington, v.41, p.719-735, 1930.

GARNER, W.W.; ALLARD, H.A. Effect of the relative length of day and night and other factors of the environment on growth and reproduction in plants. **Journal of Agricultural Research**, Washington, n.18, p.553-606, 1920.

GARNER, W.W., ALLARD, H.A. Further studies in photoperiodism, the response of the plant to relative length of day and night. **Journal of Agricultural Research**. Washington, n.23, p.871-920, 1923.

GOMES, F.P.; GARCIA, C.H. **Estatística aplicada a experimentos agrônômicos e florestais: exposição com exemplos e orientações para uso de aplicativos**. Piracicaba: FEALQ, 2002. 309p.

GOUDRIAAN, J. Potential production process. In: PENNING de VRIES, F.W.T and van Laar, H.H. (Ed.), **Simulation of plant growth and crop production**. Wageningen: Simulation Monographs. Pudoc, 1982, p.98-113.

GOUDRIAAN, J.; van LAAR, H.H. **Modeling potential crop growth processes: Textbook with exercises**. Dordrecht, Kluwer Academic Press, 1994. 238p.

GUEREÑA, A. Assessment of climate change and agriculture in Spain using climate models. **Agronomy Journal**, Madison, v.93, p.237-249, 2001.

GUIAMET, J.J.; NAKAYAMA, F. The effects of long days upon reproductive growth in soybeans, *Glycine max*, L. Merr. cv. Williams. **Crop Science**. Madison, n.53, p.35-40, 1984.

HAIR, J.F.; ANDERSON, R.E.; TATHAM, R.L.; BLACK, W.C. trad. Sant'Anna, A.S. Chaves Neto, A. **Análise multivariada de dados**. 5 ed. Porto Alegre: Bookman, 2005, 314 p.

HAN, T.; WANG, J., Studies on the postflowering photoperiodic responses in soybean. **Acta Botanica**, Sinica, n.37, p.863-869, 1995.

- HANSEN, J.; SATO, M.; RUEDY, R.; LACIS, A.; OINAS, V. Global warming in the twenty-first century: an alternative scenario. **Proceedings of the National Academy of Science**, New York, v.97, p.9875–9880, 2000.
- HASTINGS, N.A.; PEACOCK, J.B. **Statistical distributions: a handbook for students and practitioners**, Longon Butterworths, 1975. 129p.
- HEINEMANN, A. B.; DOURADO NETO, D.; MAIA, A.H.N.; INGRAM, K; HOOGENBOOM, G. Soybean (*Glycine max* (L.) Merr.) growth and development response to CO₂ enrichment under different temperature regimes. **European Journal Agronomy**, Amsterdam, v.23, n.3, p.1-13, 2005.
- HERBERT, S.J.; LITCHFIELD, G.V. Partitioning soybean seed yield components. **Crop Science**, Madison, v.22, n.5, p.1074-1079, 1982.
- HESKETH, J.D., MHYRE, D.C.; WILLEY, C.R. Temperature control of time intervals between vegetative and reproductive events in soybean. **Crop Science**, Madison, v.15, p.250–254, 1973.
- HEUVELINK, G.B.M. **Error propagation in environmental modeling with GIS**. Bristol: Taylor and Francis, 1998. 127p.
- HOFSTRA G.; HESKETH, J.D. Effects of temperature on the gas exchange of leaves in the light and dark. **Planta**, Berlin, n.85, p. 228–237, 1969.
- HOFSTRA, G., Response of soybeans to temperature under high light intensities. **Canadian Journal Plant Science**, Ottawa, v.52, p.535–543, 1972.
- HOGG, R.V.; CRAIG, A.T. **Introduction to Mathematical Statistics**, 4th Ed. New York: Macmillan, 1978, 438 p.
- HOOGENBOOM, G., JONES, J.W.; WILKENS, P.W.; BATCHELOR, W.D. **Crop models**. In. TSUJI, G.Y; UEHARA, G.; BALAS, S. (Ed.) DSSAT, v.3. Honolulu: University of Hawaii 1994, p. 95-244.
- Instituto de Pesos e Medidas do Estado de São Paulo (IMPE). Disponível em <<http://www.ipem.sp.gov.br>> acesso em 1 mar. 2006.
- IPCC, 2001. Climate change 2001: impact, adaptation, and vulnerability. A report of working Group II of the intergovernmental panel on climate change, 2001, 18 p.
- JIANG, C.J.; GAO, H.Y.; ZOU, Q.; JIANG, G.M. LI, L.H. Leaf orientation, photorespiration and xanthophyll cycle protect young soybean leaves against high irradiance in field. **Environmental and Experimental Botany**, Oxford, n.87, p.87-96, 2006.
- JIANG, H.; EGLI, D.B. Shade induced changes in flower and pod number and flower fruit abscission in soybean. **Agronomy Journal**, Madison, v.85, n.2, p.221-225, 1993.

- JOHNSON, H. W.; BORTHWICK, H. A.; LEFFEL, R. C. Effects of photoperiod and time of planting on rates of development of the soybean in various stages of the life cycle. **Botanical Gazette**, Chicago, v.22, p.77-95, 1960.
- KANTOLIC, A.G.; SLAFER, G.A., Photoperiod sensitivity after flowering and seed number determination in indeterminate soybean cultivars. **Field Crops Resource**. Oxford, n.72, p.109–118. 2001.
- KEELING, C.D.; WHORF, T.P., Atmospheric CO₂ records from the SIO air sampling network. In: (KEELING, C.D.; WHORF, T.P.) **Trends: A Compendium of Data on Global Change**. Carbon Dioxide Information Analysis Center. Oak Ridge: Oak Ridge National Laboratory, 2000, 245 p. Oxford.
- KITE, G.W. Frequency and risk analysis in hydrology, **Water Resources Publications**, Fort Collins, v.3, 395p, 1978.
- KORTE, L.L.; WILLIAMS, J.H.; SPECHT, J.E.; SORENSEN, R.C. Irrigation of soybean genotypes during reproductive ontogeny I: agronomic responses. **Crop Science**, Madison, v.23, n.3, p.521-527, 1983.
- KRAJEWSKI, S.A.; GIBBS, B.L. **Understanding Contouring: a practical guide to spatial estimation and contouring using a computer and basics of using variograms**. Oxford, Gibbs Associates, Oxford, 130p.1966.
- KUBINS, S. Measurement of radiant energy. In: SESTAK, Z.; CATSKY, J.; JARVIS, P.G. **Plant photosynthetic production, manual of methods**. Hague: W. Junk.1971, p.702-765.
- LANDIM, P.M.B.. **Introdução aos métodos de estimação espacial para confecção de mapas**. Rio Claro: UNESP. Disponível no formato PDF (Adobe Acrobat®) em <<http://www.rc.unesp.br/igce/aplicada/textodi.html>>. (Texto Didático 02, interpo.pdf). Acesso em 1 Jul. 2006.
- LANDIM, P.M.B.; STURARO, J.R. **Krigagem indicativa aplicada à elaboração de mapas probabilísticos de riscos**. DGA, IGCE, UNESP/Rio Claro, Lab. Geomatemática, Texto Didático 06, 19 pp. 2002. Disponível em <<http://www.rc.unesp.br/igce/aplicada/textodi.html>>. Acesso em 1 Jul. 2006.
- LARCHER, W. **Ecofisiologia vegetal**. São Carlos: RiMa, 2000, 531p.
- LAWN, R.J.; BYTH, D.E. Response of soya beans to planting date in South-Eastern Queensland. I. Influence of photoperiod and temperature on phasic development patterns. **Australian Journal of Agricultural Research**, Collingwood, v.24, p.67-80, 1973.
- LEHNINGER, A.L. **Bioquímica**. 2.ed. Tradução de J.R. Magalhães. São Paulo: Edgard Blücher, 1976, 2v, 134p.
- LEOPOLD, L.B.; LANGBEIN, W.B. **The concept of entropy in landscape evolution**. U.S. Geological Survey Professional Paper, 500-A, 1962.

- LIU, W.T.H.; LIU, B.W.Y. Modelo de previsão de produtividade de soja no Estado de Minas Gerais. In: CONGRESSO INTERAMERICANO DE METEOROLOGIA 1., 1986, Brasília. **Anais...** Brasília:Sociedade Brasileira de Meteorologia, 1986. p.15-18.
- LOZARDA, B.I.; ANGELOCCI, L.R. Efeito da temperatura do ar e da disponibilidade hídrica do solo na duração de subperíodos e na produtividade de um híbrido de milho (*Zea mays*, L.). **Revista Brasileira de Agrometeorologia**, Santa Maria, v.7, n.1, p.37-43, 1999.
- LYRA, G.B.; GARCIA, B.I.L., PIEDADE, S. M.S. Regiões homogêneas e funções de distribuição de probabilidade da precipitação pluvial no Estado de Táchira, Venezuela. **Pesquisa Agropecuária Brasileira**, Brasília, v.41, n.2, p.205-215. 2006.
- MAEHLER, A.R.; PIRES, J.L.F.; COSTA, J.A; FERREIRA, F.G. , Potencial de rendimento de soja durante a ontogenia em razão da irrigação e arranjo de plantas. **Pesquisa Agropecuária Brasileira**, Brasília, v.38, n.2, p.225-231, 2003.
- MAGALHÃES, A.C.N. Fotossíntese. In.: FERRI, M.G. (Coord.) **Fisiologia vegetal**, São Paulo, EPU, 1985, v.1, 362p.
- MAJOR, D.J. Photoperiod response characteristics controlling flowering of nine crop species. **Canadian Journal of Plant Science**. Ottawa, n.60, p.777–784, 1980.
- MAJOR, D.J.; JOHNSON, D. R.; TANNER, J.W.; ANDERSON, I. C. Effects of daylength and temperature on soybean development. **Crop Science**, Madison, v.15, p.174-179, 1975b.
- MAJOR, D.J.; JOHNSON, D.R.; LUEDDERS, V.D. Evaluation of eleven thermal unit methods for predicting soybean development **Crop Science**, Madison, v.15, p.172-174, 1975a.
- MANN, J.D.; JAWORSKI, E.G. Comparison of stresses which may limit soybean yield. **Crop Science**, Madison, n.10, p.620–624, 1970.
- MARDIA, K.V. Measures of multivariate skewness and kurtosis with applications. **Biometrika**, London, v.57, n.3, p.519-530, 1970.
- MARTINS, M.J. **Simulação**. Lisboa, Instituto Superior de Agronomia. pt. 1, 2003, 60 p.
- MASON, W.K.; SMITH, R.C.G. irrigation for crops in a subhumid environment: the water requirements of soybeans. **Irrigation Science**, Berlin, v.2, p.13-22, 1980.
- MATHERON, G. **The theory of regionalized variables and its applications**. Fointanebleu: Cahiers du Centre de Morphologie Mathématique de Fointanebleu, 1971. 211p.
- MATSUMOTO, M.; KURITA, Y. Strong deviations from randomness in *m*-sequences based on trinomials. **ACM Transformation on Modeling and Computer Simulation**, Amsterdam, n.6, p.99–106, 1996.
- MATSUMOTO, M.; KURITA, Y. Twisted GFSR generators II. **ACM Transformation on Modeling and Computer Simulation**, Amsterdam, n.4, p.254–266, 1994.

- MATSUMOTO, M.; KURITA, Y. Twisted GFSR generators. **ACM Trans. on Modeling and Computer Simulation**, n.2, p.179–194, 1992.
- MATSUMOTO, M.; NISHIMURA, T. A nonempirical test on the weight of pseudorandom number generators, In: FANG, K.T.; HICKERNEL, F.J.; NIEDERREITER, H. (Ed.), **Monte Carlo and Quasi-Monte Carlo Methods 2000**, Amsterdam, Springer, 2002, p. 381–395.
- MATSUMOTO, M.; NISHIMURA, T. Mersenne Twister: a 623-dimensionally equidistributed uniform pseudo-random number generator. **ACM Transformation on Modeling and Computer Simulation**, Amsterdam, n.8, p.3–30, 1998.
- MATZENAUER, R. Estimativa do consumo relativo de água para a cultura do milho no Estado do Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.10, n.1, p.35-43, 2002.
- MATZENAUER, R.; CARGNELUTTI FILHO, A.; ANJOS, C.S. Probabilidade de ocorrer precipitação pluvial igual ou superior à evapotranspiração máxima na cultura de soja, no Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.11, n.2, p.313-320, 2003.
- McBLAIN, B.A.; HUME, D.J. Reproductive abortion, yield componentes and nitrogen content in three early soybean cultivares. **Canadian Journal of Plant Science**, Ottawa, v.61, n.3, p.499-505, July 1981.
- McQUIGG, J.D. The promise of food and climate information systems. In: SLATER, L.E.; LEVIN, S.K. (Ed.) **Climate's impact of food supplies**. Boulder, Colorado: American Association for the Advancement of science, Westview Press, 1981. 243p. (Selected Symp, 62).
- MELTON, M.A., Methods of measuring the effect of environmental factors on channel properties. **Journal of Geophysical Research**, Ottawa, n.67, p.1485-1490, 1962.
- MENDELSON, R.; ROSENBERG, N.J., Framework for integrated assessments of global warming impacts. **Climate Change**, Amsterdam, v.28, p.15–44, 1994.
- MIRSHAWKA, V. **Estatística**, São Paulo: Nobel, 1971, v.2, 367p.
- MONTEITH, J.L. Validity of the correlation between intercepted radiation and biomass. **Agricultural and Forestry Meteorology**. Amsterdam, v.68, p.220- 231, 1994.
- MORANDI, E.N.; CASANO, L.M.; REGGIARDO, L.M. Postflowering photoperiodic effect on reproductive efficiency and seed growth in soybean. **Field Crops Resource**. Oxford, n.18, p.227–241, 1988.
- MORETTIN, P.A.; BUSSAB, W.O. **Estatística básica**. 5. ed., São Paulo: Saraiva, 2003. 526p.
- MORISAWA, M., Topological properties of delta distributory networks. In.: WOLDENBERG (Ed.) **Models in geomorphology**. Londres: George Allen,Unwin, 1985, p.239-268.

MORRISON, D.F. **Multivariate statistical methods**. 3th ed. McGraw-Hill Publishing. 495p. 1990.

MOTA, F.S.; ROSSKOFF, J.L.C.; SILVA, J.B. Probabilidade de ocorrência de dias com temperaturas iguais ou superiores a 35°C no florescimento do arroz no Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.7, p.147-149, 1999.

MUCHOW, R. C.; ROBERTSON, M. J.; PENGELLY. Radiation-use efficiency of soybean, mungbean and cowpea under different environmental conditions. **Field Crops Research, Oxford**, v.32, p.1-16, 1993.

MÜLLER, L. Fotossíntese. In.: MYIASAKA S.; MEDINA, J.C. (Ed.). **A soja no Brasil**. Campinas: UNICAMP, 1981, p.109-129.

MUNAKATA, K. Simulation of population photosynthesis and dry matter production. In MATSUO, T.; KUMAZAWA, K. ISHII, R.; ISHIHARA, K.; HIRATA, H. (Ed.). **Science of the rice plant**, Amsterdam: Physiology, food and Agricultural policy Research Center, 1995, v.2, p.671-684.

NIELSON, C.S. Effects of photoperiod on microsporogenesis in Biloxi soybean. **Botany Gazette**, Chicago, n.104, p.99–106, 1942.

NISHI, A.Y.M.; HUNGRIA, M. Efeito da reinoculação na soja [*glycine max* (L.) merrill] em um solo com população estabelecida de *bradyrhizobium* com as estirpes semia 566, 586, 587, 5019, 5079 e 5080. **Pesquisa Agropecuária Brasileira**, Brasília, v.31, n.5, p.359-368, ago, 2000.

OMETTO, J.C. **Bioclimatologia vegetal**. São Paulo: Agronômica Ceres, 1981. 440p.

ORTIZ, J.O.; FELGUEIRAS, C.A.; DRUCK, S. Modelagem de fertilidade do solo por simulação estocástica com tratamento de incertezas. **Pesquisa Agropecuária Brasileira**, Brasília, v.39, n.4, p.379-389, 2004.

PANDOLFO, C. **Parâmetros básicos para uso na modelagem do rendimento de matéria seca em alfafa (*Medicago sativa* L.)**. 1995. 128 p. Dissertação (Mestrado em Agronomia) – Faculdade de Agronomia, Universidade do Rio Grande do Sul, Porto Alegre, 1995.

PARKER, M. W.; BORTHWICK, H. A. Influence of temperature on photoperiodic reactions in leaf blades of Biloxi soybean. **Botanical Gazette**, Chicago, v.104, p.612-619, 1943.

PASCALE, A. J. Tipos agroclimáticos para el cultivo de la soya en la Argentina. **Revista de la Facultad de Agronomía e Veterinaria**, Buenos Aires, v.17, p.31-38, 1969.

PASCALE, A.J.; FLEURAT, F.; LESSARD, L.; CONAN, L. Reacción de distintas variedades de soja a los factores bioclimáticos de Buenos Aires. **Revista da Faculdade de Agronomia Veterinária de Buenos Aires**, Buenos Aires, v.15, n.3, p.29-54, 1963.

PAUSTIAN, R.; PARTON W.J.; PERSSON J. Modeling soil organic matter in organic-amended and nitrogen-fertilized long-term plots. **Soil Science Society America Journal**, Madison, v.56, p.476-488, 1992.

- PEREIRA, A.R.; ANGELOCCI, L.R.; SENTELHAS, P.C.; **Agrometeorologia: Fundamentos e Aplicações Práticas**. Piracicaba, Agropecuária, 2002, 477 p.
- PEREIRA, A.R.; MACHADO, E.C. Um simulador dinâmico do crescimento de uma cultura de cana-se-açúcar. **Bragantia**, Campinas, n.45, v.1, p.107-122, 1986.
- PEREIRA, A.R.; VILLA NOVA, N.A.; SEDIYAMA, G.C. **Evapotranspiração**. Piracicaba: FEALQ, 1997. 183 p.
- PESSOA, M.C.P.Y.; LUCHIARI JUNIOR, A.; FERNANDES, E.N.; LIMA, M.A. **Principais modelos matemáticos e simuladores utilizados para a análise de impactos ambientais das atividades agrícolas**. Brasília, EMBRAPA, 1997, 44p.
- PIRES, COSTA, J. A.; THOMAS, A. L.; MAEHLER, A. R. Efeito de populações e espaçamentos sobre o potencial de rendimento de soja durante a ontogenia. **Pesquisa Agropecuária Brasileira**. Brasília, v.35, n.8, p.1541-1547, 2000.
- PIRES, J.L.F. et al. Efeito de populações e espaçamentos sobre o potencial de rendimento de soja durante a ontogenia. **Pesquisa Agropecuária Brasileira**, Brasília, v.35, n.8, p.1541-1547, ago, 2000.
- QUEIROZ, E.F.; MOLION, L.C.B.; MINOR, H.C.; NEUMAIER, N. Um modelo matemático de quantificação do efeito da disponibilidade hídrica em soja. **Pesquisa Agropecuária Brasileira**, Brasília, v.31, n.10, p.683-690, 1996.
- RAPER Jr., C.D.; THOMAS, J.F. Photoperiodic alteration of dry matter partitioning and seed yield in soybean. **Crop Science**. Madison, n.18, p.654-656, 1978.
- RIMMINGTON, G.M.; CHARLES-EDWARDS, D.A. Mathematical descriptions of plant growth and development. In: WISIOL, K.; HESKETH, J.D. **Plant growth modeling for resource management: current models and methods**. Boca Raton: CRC Press, 1987. v.1, p.3-15.
- RODRIGUES, O.; DIDONET, A.D.; LHAMBY, J.C.B.; BERTAGNOLLI, P.F.; LUZ, J.S.; Resposta quantitativa do florescimento de soja à temperatura e ao fotoperíodo. **Pesquisa Agropecuária Brasileira**, Brasília, v.36, n.3, p.431-437, 2001.
- ROLIM, G.S.; SENTELHAS, P.C.; UNGARO, M.R.G. Análise de risco climático para a cultura de girassol, em algumas localidades de São Paulo e do Paraná, usando os modelos DSSAT/OILCROP-SUN e FAO. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.9, n.1, p.91-102, 2001.
- SALINAS, A.R.; ZELENER, N.; CRAVIOTTO, R.M.; BISARO, V. Respuestas fisiológicas que caracterizan el comportamiento de diferentes cultivares de soja a la deficiencia hídrica. **Pesquisa Agropecuária Brasileira**, Brasília, v.31, n.5, p. 331-338, 1996.
- SANTOS, A.C.; FERREIRA, D.F. Definição do tamanho amostral usando simulação Monte Carlo para o teste de normalidade baseado em assimetria e curtose. II. Abordagem multivariada. **Ciência e Agrotecnologia**, Lavras, v.27, n.1, p.62-69, 2003a.

SANTOS, A.C.; FERREIRA, D.F. Definição do tamanho amostral usando simulação Monte Carlo para o teste de normalidade baseado em assimetria e curtose. I. abordagem univariada. **Ciência e Agrotecnologia**, Lavras, v.27, n.2, p.432-437, 2003b.

SCHÖFFEL, E.R.; VOLPE, C.A. Eficiência de conversão da radiação fotossinteticamente ativa interceptada pela soja para a produção de fitomassa. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.9, n.2, p.241-249, 2001.

SEDIYAMA, G.C.; CHANCELLOR, W.J.; BURKHARDT, T.H.; GOSS, J.R. Simulação de parâmetros climáticos para a época de crescimento de plantas. **Revista Ceres**, Viçosa, v.25, n.141, p.455-466, 1978.

SEDIYAMA, T.; PEREIRA, M.G.; SEDIYAMA, C.S.; GOMES, J.L.L. **Cultura de soja**; Viçosa: Universidade Federal de Viçosa, 1985. pt1. 96p.

SEGOVIA, R.M.; ANDRADE, E.G. Um modelo de determinação do efeito da precipitação pluviométrica na produtividade agrícola. In. SERGOVIA, R.M. (Ed). **Determinação do efeito da precipitação pluviométrica na produtividade agrícola**. Brasília: CFP. 1982. p.10-18. (Coleção Análise e Pesquisa, 24).

SENTELHAS, P.C.; ORTOLANI, A.A.; PEZZOPANE, J. R. M. Estimativa da temperatura mínima e da diferença entre o abrigo e a relva, em noites de geada. **Bragantia**, Campinas, v.54, n.2, p.437-344, 1995.

SHARMA, K.; DYBING, C.D.; LAY, C. Soybean flower abortion: genetics and impact of selection on seed yield. **Crop Science**, Madison, v.30, n.5, p.1017-1022, Sept./Oct. 1990.

SHIBLES, R. M.; WEBER, C.R. Interception of solar radiation and dry matter production by various soybean planting patterns. **Crop Science**, Madison, v.6, n.1, p.159-176, 1966.

SHIBLES, R.M.; ANDERSON, T.C.; GIBSON, A.H. Soybean. In.: EVANS, L.T. (Ed) **Crop physiology**. Cambridge: Cambridge University, 1975, p.151-189,

SHIBLES, R.M.; WEBER, C.R. Leaf area, solar radiation interception, and dry mater production by various soybean planting patterns. **Crop Science**, Madison, v.6, p.55-59, 1965.

SILVA, J.B.; BURGUEÑO, L.E.T. Estimativa do potencial eólico a partir de tabelas de probabilidades da velocidade média pentadal do vento, na Cascata, em Pelotas – RS. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.9, n.2, p.333-338, 2001.

SILVA, J.B.; BURGUEÑO, L.E.T.; FERREIRA, C.C. Umidade relativa em Pelotas, RS. II – Tabelas de probabilidades das médias e máximas pentadiais. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.10, n.2, p.323-331, 2002.

SILVA, J.B.; LARROZA, E.G. Probabilidades de ocorrência de diferentes velocidades dos ventos em Pelotas, RS. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.7, n.1, p.91-99, 1999.

SILVA, J.B.; LOPART, M.P.; FERREIRA, C.C. Temperatura média do ar em Pelotas, Rio Grande do Sul. – Tabelas de probabilidades das médias e máximas pentadais. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.13, n.1, p.103-111, 2005.

SINCLAIR, T.R.; NEUMAIER, N.; FARIAS, J.R.B.; NEPOMUCENO, A.L.; Comparison of vegetative development in soybean cultivars for low-latitude environments. **Field Crops Research**, Amsterdam, n.92, p.53–59, 2005.

SIONIT, N., STRAIN, B.R., FLINT, E.P. Interaction of temperature and CO₂ enrichment on soybean: photosynthesis and seed yield. **Canadian Journal Plant Science**, Ottawa, v.67, p.629–636, 1987.

SIONIT, N.; KRAMER, P. J. Effects of water stress during different stages of growth of soybean. **Agronomy Journal**, Madison, v.69, n.2, p.274-278, 1977.

SIQUEIRA, O.J.F.; FARIAS, J.R.B.; SANS, L.M.A.. Potential effects of global climate change for Brazilian agriculture and adaptive strategies for wheat, maize and soybean. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.2, p.115-129, 1994.

Sistema Meteorológico do Paraná, SIMEPAR, 2006. Disponível em <<http://www.simepar.br/>>, acesso em 1 jul. 2006.

SONOIKE, K. Various aspects of inhibition of photosynthesis under light/chilling stress: photoinhibition at chilling temperatures versus chilling damage in the light. **Journal Plant Research**, local. v.111, p.121–129, 1998.

SOUSA, S.A.V.; PERES, F.C., Programa computacional para simulação da ocorrência de veranicos e queda de rendimento. **Pesquisa Agropecuária Brasileira**, Brasília, v.33, n.12, p.1951-1956, dez. 1998.

SPOLEN, W.G.; WIEBOLD, W.J.; GLENN, D.S. Intraraceme competition in field-grown soybean. **Agronomy Journal**, Madison, v.78, n.2, p.280-283, 1986.

STEEL, R.G.D.; TORRIE, J.H.; DICKEY, A. **Principles and procedures of statistics a biometrical approach**. 3rd ed. Nova York: McGraw-Hill, 1997. 666p.

STEWART, COBER, E.R.; BERNARD, R.L. Modeling Genetic Effects on the Photothermal Response of Soybean Phenological Development. **Agronomy Journal**, Madison, v.95, p.65–70, 2003.

STULP, V.J. Evolução regional da produtividade da mão-de-obra na agropecuária gaúcha: uma aplicação da matriz de Markov. **Revista de Economia e Sociologia Rural**, Rio de Janeiro, v.42, n.2, p.293-316, 2004.

TAIZ, L.; ZIEGER, E. **Fisiologia vegetal**. Trad. SANTARÉM, E. R., 3. ed., Porto Alegre: Artemed, 2004, p.719.

- TAYLOR, K.E.; MacCRACKEN, M.C., Projected effects of increasing concentrations of carbon dioxide and trace gases on climate. In: KIMBALL, B.A., ROSENBERG, N.J., ALLEN JR., L.H. (Ed.), Impact of carbon dioxide, trace gases, and climate change on global agriculture.(ASA Special Publication, 53). **American Society of Agronomy Inc.**, Madison: 1990, p. 1–17.
- THOM, H.C.S. **Some methods of climatological analysis**. Roma: FAO, 1966. 50p. (Technical Notes 81).
- THOMAS, A.L.; COSTA, J.A. Influência do déficit hídrico sobre o desenvolvimento e rendimento de soja. **Pesquisa Agropecuária Brasileira**, Brasília, v.29, n.9, p.1389-1396, 1994.
- THOMAS, F.J.; RAPER Jr.; C.D. Photoperiodic control of seed filling for soybeans. **Crop Science**, Madison, n.16, p.667–672, 1976.
- THORNLEY, J.H.M. **Mathematical models in plant physiology: a quantitative approach to problems in plant and crop physiology**. London: Academic Press, 1976. 318p.
- THORNTHWAITE, C.W. An approach towards a rational classification of climate. **Geographical Review**, London, n.38, p. 55-94, 1948.
- THORNTHWAITE, C.W., MATHER, R.J. **The water Balance**. New Jersey: Laboratory of Climatology, v.8, 1955. 104 p. (Publication in Climatology).
- VENTIMIGLIA, L.A.; COSTA, J.L.; THOMAS, A.L.; PIRES, J.L.F. Potencial de rendimento de soja em razão da disponibilidade de fósforo no solo e dos espaçamentos. **Pesquisa Agropecuária Brasileira**, Brasília, v.34, n.2, p.195-199, 1999.
- VERNICH, L.; ZUANNI, F. About the minimum Number of Years Required to Stabilize the Solar Irradiation Statistical Estimates. **Solar Energy**, Amsterdam, v.57, n.6, p.445-447, 1996
- VILLA NOVA, N.A.; PEDRO JÚNIOR, M.J.; PEREIRA, A.R.; OMETTO, J.C. Estimativa de graus-dia acumulado acima de qualquer temperatura basal, em função das temperaturas máxima e mínima. **Caderno de Ciência da Terra**, São Paulo: USP, Instituto de Geografia, 1972, 8p.
- VILLA NOVA, N.A.; SANTIAGO, A.V.; RESENDE, F.C. **Energia solar: aspectos físicos e de captura pela biomassa**. Piracicaba: ESALQ/USP, 2001. 20p.
- VOSSSEN, P. Comparative statistical validation of two tem-day water-use models and three yield-reduction hypotheses for yield assessment in Botswana. **Agricultural and Forest Meteorology**. Amsterdam. v.51. p.177-195, 1990.
- VRIES, P.F.W.T.; LAAR, H.H.; CHARDON, M. C. M. Bioenergetics of growth of seeds, fruits and storage organs. In: Symposium on Potential Productivity of Field Crops Under Different Environments. Los Baños, Philippines, IRRI, 1983. p37-59.
- WATSON, R.T.; RODHE, H.; OESCHGER, H.; SIEGENTHALER, U. Greenhouse gases and aerosols. In: HOUGHTON, J.T., JENKINS, G.J., EPHRAUMS, J.J. (Ed.), **Climate change: The IPCC scientific assessment**. Cambridge: Cambridge University Press, 1990, p. 1-40.

WEIBULL, W.A. A Statistical distribution function of wide Applicability, ASME. **Journal of Applied Mechanics**, Amsterdam, n.18, p.293-297, 1951.

WESTGATE, M. E. SCHUSSLER, J.R., REICOSKY, D.C.; BRENNER, M.L. Effect of water deficits on seed development in soybean. **Plant Physiology**, Lancaster, v.91, n.2, p.980-985, 1989.

WIEBOLD, W.J. Rescue of soybean flowers destined to abscise. **Agronomy Journal**, Madison, v.82, n.1, p.85-88, 1990.

WIEBOLD, W.J.; PANCIERA, M.T. Vasculature of soybean racemes with altered intraraceme competition. **Crop Science**, Madison, v.30, n.5, p.1089-1093, 1990.

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

WU, H.; CHILDRESS, W.M.; LI, Y.; SPENCE, R.D.; REN, J. An integrated simulation model for a semiarid agroecosystem in the Loess Plateau of North-western China. **Agricultural Systems**, Cambridge, v.52, p.83-111, 1996.

ZHANG, L., WANG, R.; HESKETH, J.D. Effects of photoperiod on growth and development of soybean floral bud in different maturity. **Agronomy Journal**, Madison, n.93, p.944-948, 2001.

ANEXOS

ANEXO 1

Tabela 32 - Estações convencionais de coleta de dados, latitude (Lat, graus), longitude (Log, graus), altitude (Alt, m), ano inicial e final das variáveis avaliadas temperatura mínima (Tmin, °C), temperatura máxima (Tmax, °C), insolação (h.d⁻¹), precipitação (mm) e fonte dos dados para o estado de São Paulo

Local	Lat	Lon	Alt	Tmin		Tmax		Insolação		Precipitação		Fonte
				Inicial	Final	Inicial	Final	Inicial	Final	Inicial	Final	
Adamantina (SP)	-21,6833	-51,0083	443	1982	2002	1982	2002	---	---	1982	2002	IAC
Assis (SP)	-22,6666	-50,4333	563	1988	2002	1988	2002	---	---	1988	2002	IAC
Ataliba Leonel (SP)	-23,1616	-49,3333	589	1961	2002	1961	2002	---	---	1961	1961	IAC
Campinas (SP)	-22,9000	-47,0008	674	1890	2003	1890	2003	1960	2004	1890	2004	IAC
Capão Bonito (SP)	-24,0033	-48,3666	702	1978	2002	1978	2002	1991	2002	1946	2002	IAC
Cravinhos (SP)	-21,1100	-47,4800	621	1997	2002	1997	2002	1997	2002	1997	2002	IAC
Gália (SP)	-22,3000	-49,5500	522	1979	2002	1979	2002	1977	2002	1979	2002	IAC
Guairá (SP)	-20,3300	-47,2600	490	1997	2005	1997	2005	1997	2005	1997	2005	IAC
Itararé (SP)	-24,2500	-49,2500	1150	1977	2002	1977	2002	1977	2000	1974	2002	IAC
Jaú (SP)	-22,2833	-48,5666	580	1955	2002	1955	2002	1955	2002	1955	2002	IAC
José Bonifácio (SP)	-21,0666	-49,7000	470	1993	1994	1993	1994	---	---	1993	1994	IAC
Jundiaí (SP)	-23,2000	-46,8833	715	1968	2000	1968	2000	1993	1999	1941	2003	IAC
Limeira (SP)	-22,5333	-47,4500	639	1958	2000	1958	2000	1980	2004	1970	2003	IAC
Manduri (SP)	-23,1000	-49,2000	589	1997	2002	1997	2002	1997	2002	1997	2002	IAC
Matão (SP)	-21,8833	-48,4166	551	1993	1994	---	---	---	---	---	---	IAC
Mococa (SP)	-21,4666	-47,0016	665	1959	2000	1959	2000	1959	2000	1959	2001	IAC
Monte Alegre do Sul (SP)	-22,6833	-46,7166	777	1981	2000	1981	2000	1981	2000	1981	2000	IAC
Nova Odessa (SP)	-22,7833	-47,3000	528	1981	1999	1981	1999	1981	1995	1981	2000*	IAC
Pariqueraçu (SP)	-24,7166	-47,8833	25	1981	2000	1981	2000	1980	2000	1980	2000	IAC
Pindamonhangaba (SP)	-22,9166	-45,4500	560	1981	2000	1981	2000	1982	2000	1991	2002	IAC
Pindorama (SP)	-21,2166	-48,9333	562	1965	2000	1965	2000	1965	2000	1951	2000	IAC
Piracicaba (SP)	-22,2166	-48,9333	546	1917	2005	1917	2005	1926	2005	1917	2005	ESALQ
Ribeirão Preto (SP)	-21,1833	-47,8000	621	1939	2000	1939	2000	1965	2000	1939	2003	IAC
São Roque (SP)	-23,5333	-47,1333	850	1985	2000	1985	2000	---	---	1988	2000	IAC
Tatuí (SP)	-23,3333	-47,8666	600	1981	1999	1981	2000	1992	2000	1988	2000	IAC
Tietê (SP)	-23,0116	-47,7166	538	1981	2000	1981	2000	1991	2000	1987	2000	IAC
Ubatuba (SP)	-23,4500	-45,0066	8	1981	2000	1981	2000	1991	2003	1984	2002	IAC
Votuporanga (SP)	-20,4166	-49,9833	505	1991	2000	1991	2000	1996	1998	1991	2000	IAC

Tabela 33 - Relação das estações convencionais de coleta de dados, latitude (Lat, dec), longitude (Log, dec), altitude (Alt, m), ano inicial e final das variáveis avaliadas temperatura mínima (Tmin), temperatura máxima (Tmax), insolação, precipitação e fonte dos dados, para cidades não pertencentes ao estado de São Paulo

Local	Lat	Lon	Alt	Tmin		Tmax		Insolação		Precipitação		Fonte
				Inicial	Final	Inicial	Final	Inicial	Final	Inicial	Final	
Campo Grande (MS)	-20,4330	-54,7160	530	1997	2002	1997	2002	1997	2002	1997	2002	INMET
Lavras (MG)	-21,7500	-45,0000	918	1997	2002	1997	2002	1997	2002	1997	2002	INMET
Uberlândia (MG)	-18,9160	-48,2500	868	1997	2002	1997	2002	1997	2002	1997	2002	INMET
Cascavel (PR)	-24,8800	-53,5500	719	1997	2005	1997	2005	1997	2005	1997	2005	SIMEPAR
Londrina (PR)	-23,3166	-51,1333	566	1997	2005	1997	2005	1997	2005	1997	2005	SIMEPAR

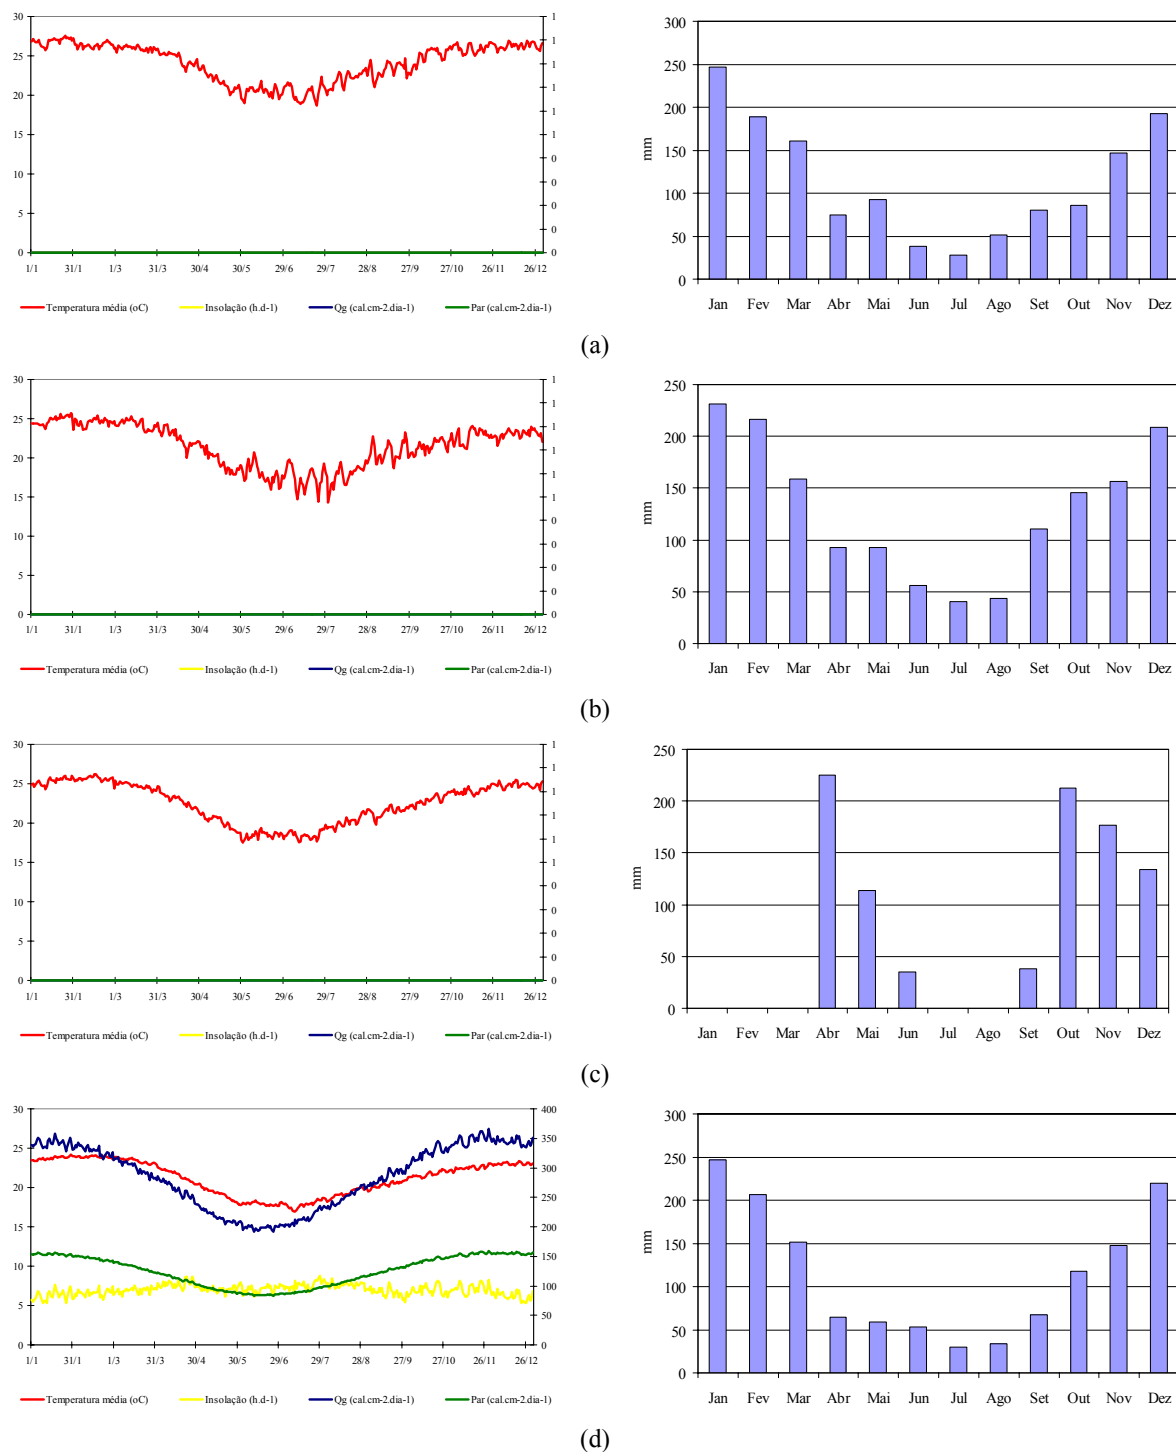


Figura 18 - Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h d^{-1}), Irradiância Solar Global (Qg , $\text{cal cm}^{-2} \text{dia}^{-1}$), Radiação Fotossinteticamente Ativa (Par , $\text{cal cm}^{-2} \text{dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coleta de dados localizados nos municípios de Adamantina (a), Assis (b), Ataliba Leonel (c) e Campinas (d)

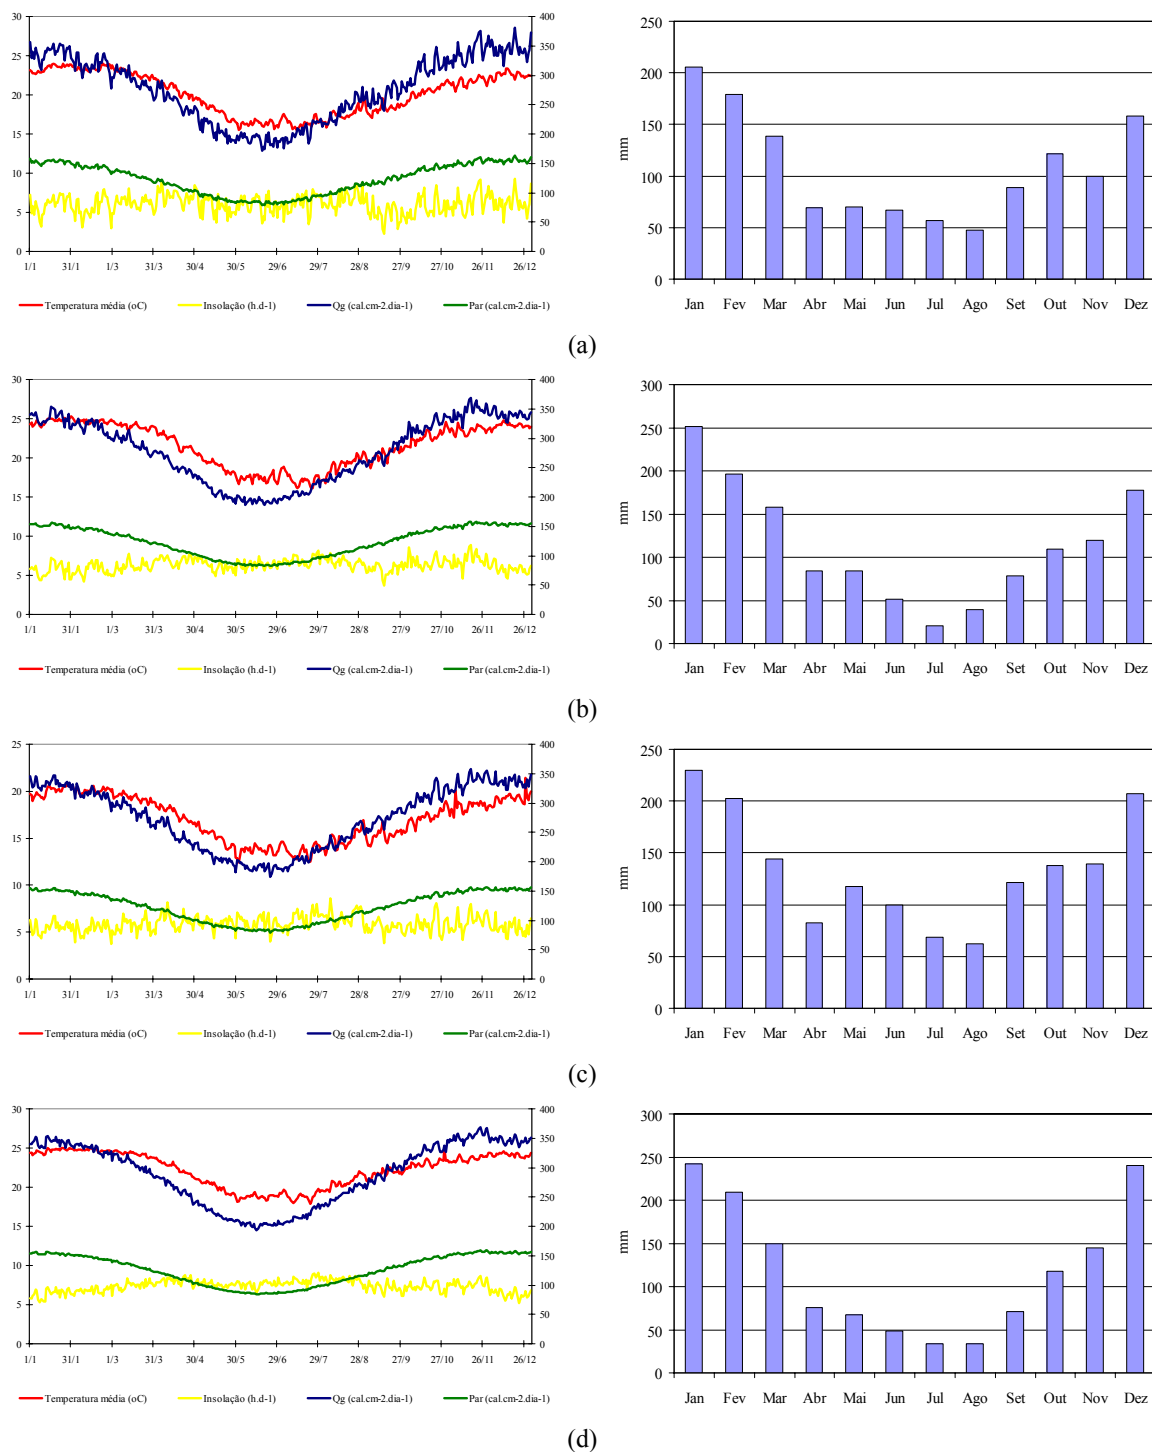


Figura 19 - Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h d^{-1}), Irradiância Solar Global (Qg , $\text{cal.cm}^{-2}\text{.dia}^{-1}$), Radiação Fotossinteticamente Ativa (Par , $\text{cal.cm}^{-2}\text{.dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coleta de dados localizados nos municípios de Capão Bonito (a), Gália (b), Itararé (c) e Jaú (d)

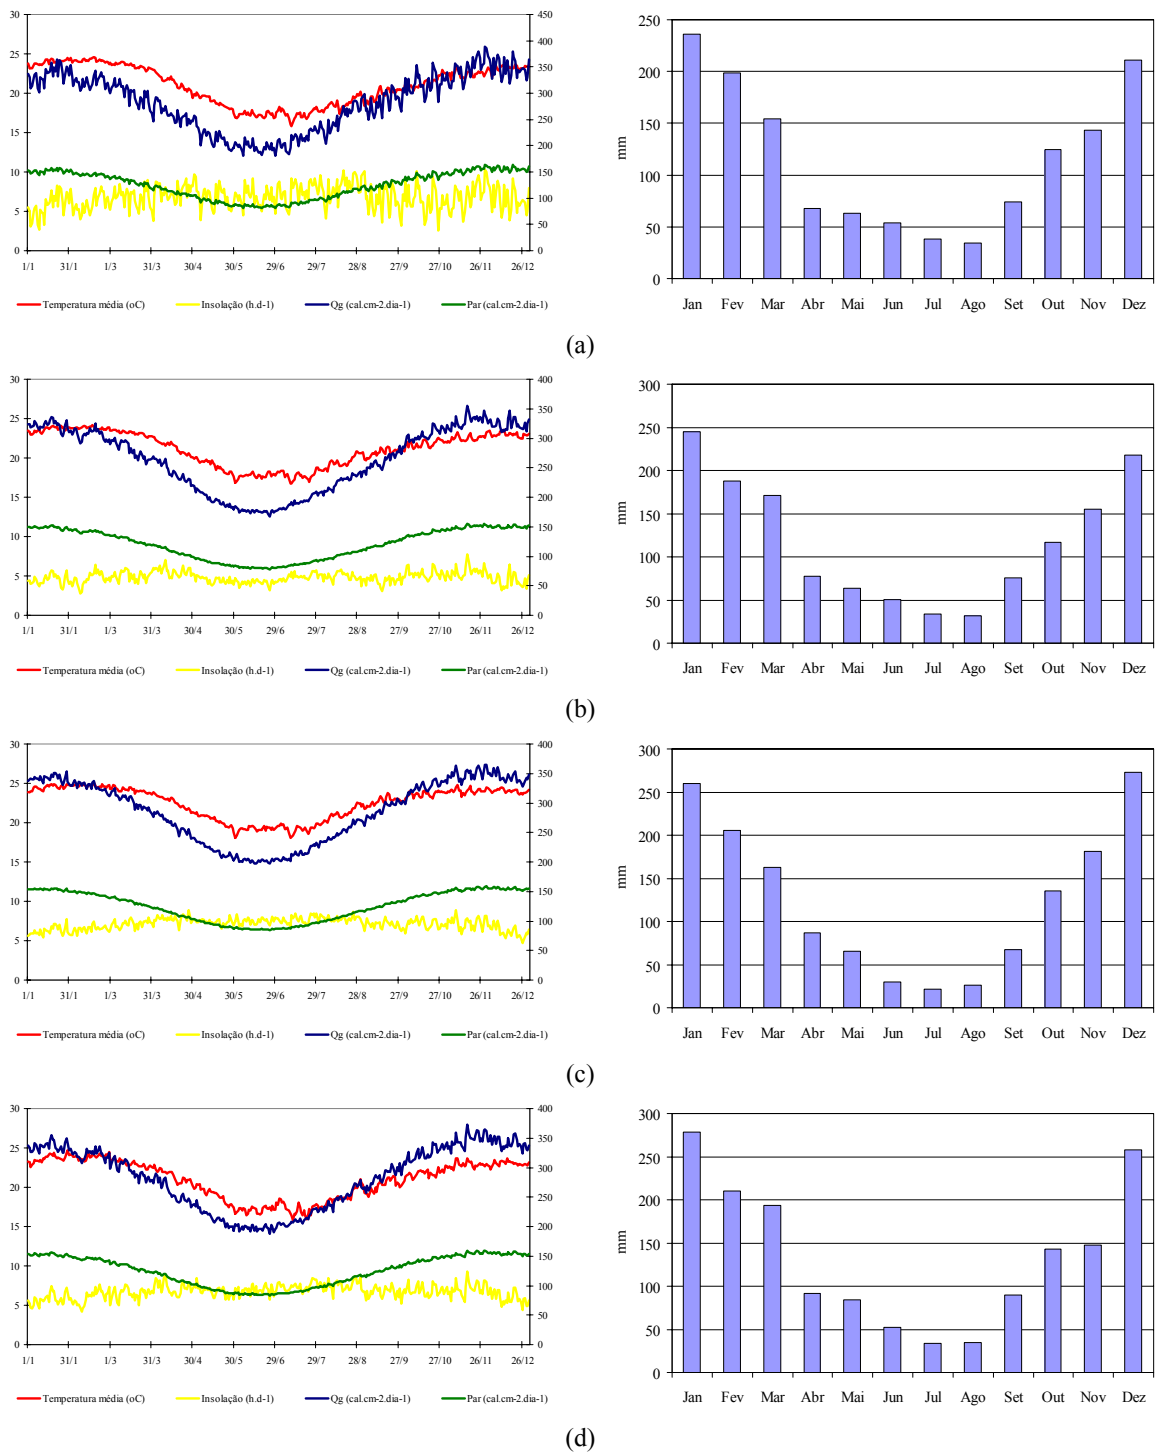


Figura 20 - Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h d^{-1}), Irradiância Solar Global (Qg , $\text{cal.cm}^{-2}.\text{dia}^{-1}$), Radiação Fotossinteticamente Ativa (Par , $\text{cal.cm}^{-2}.\text{dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coleta de dados localizados nos municípios de Jundiá (a), Limeira (b), Mococa (c) e Monte Alegre do Sul (d)

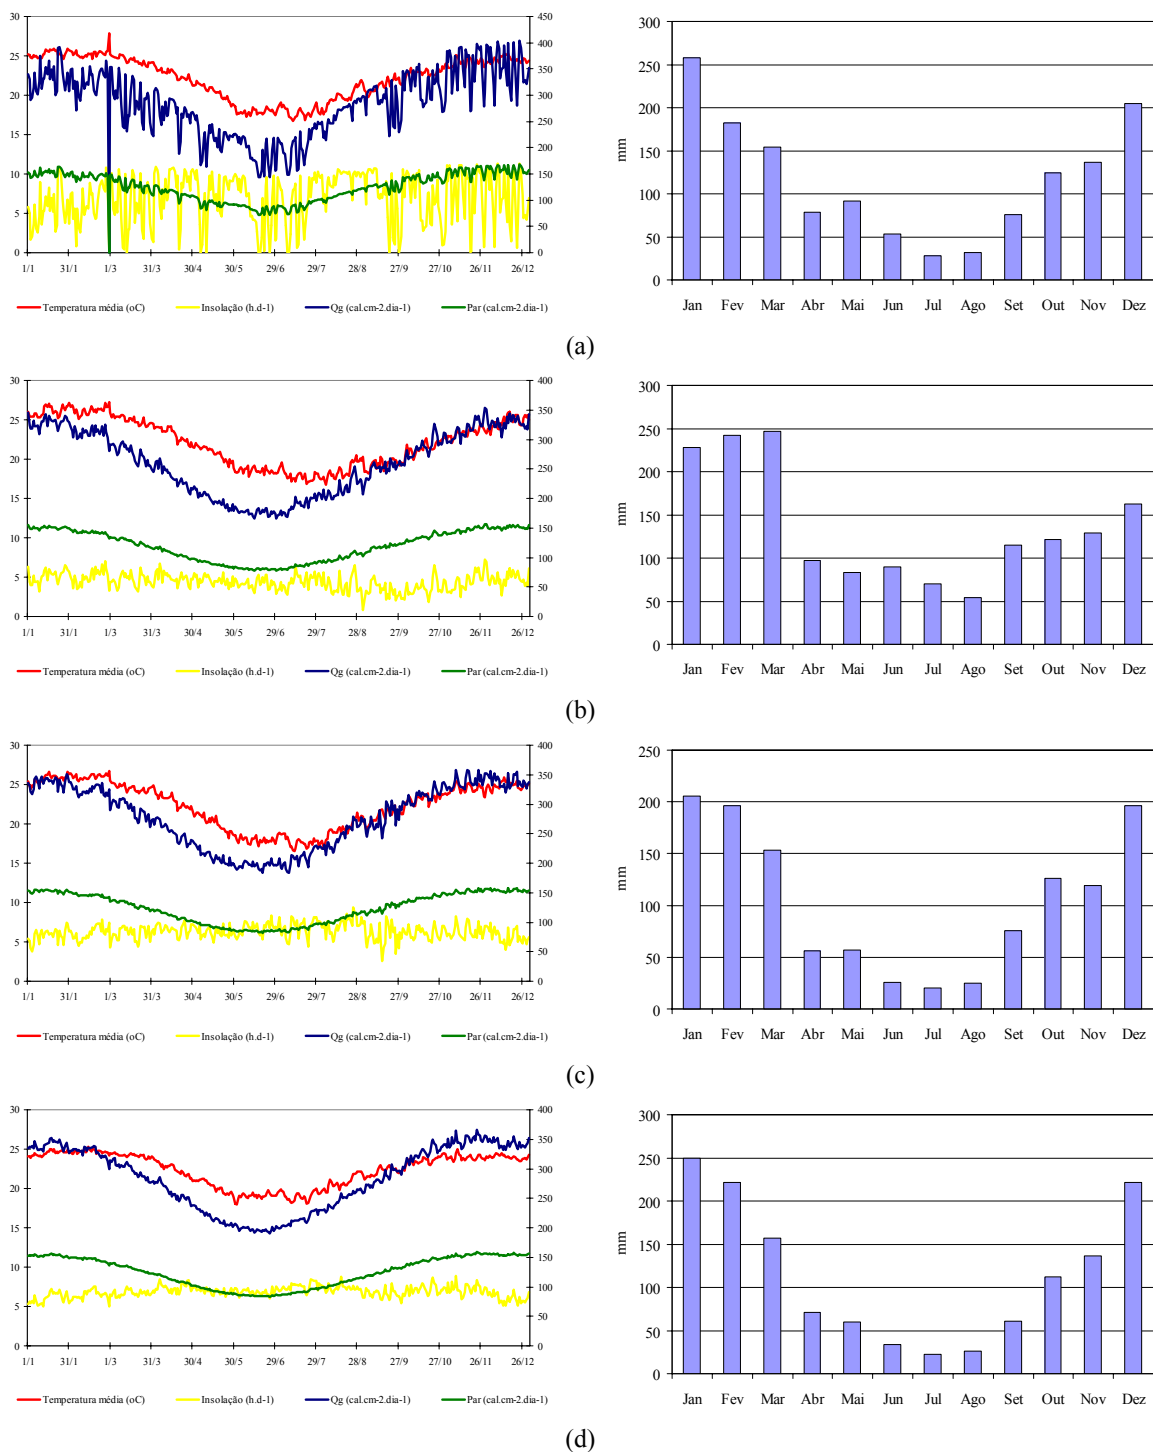


Figura 21 - Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h.d^{-1}), Irradiância Solar Global (Q_g , $\text{cal.cm}^{-2}.\text{dia}^{-1}$), Radiação Fotossinteticamente Ativa (Par , $\text{cal.cm}^{-2}.\text{dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coleta de dados localizados nos municípios de Nova Odessa (a), Pariquera (b), Pindamonhangaba (c) e Pindorama (d)

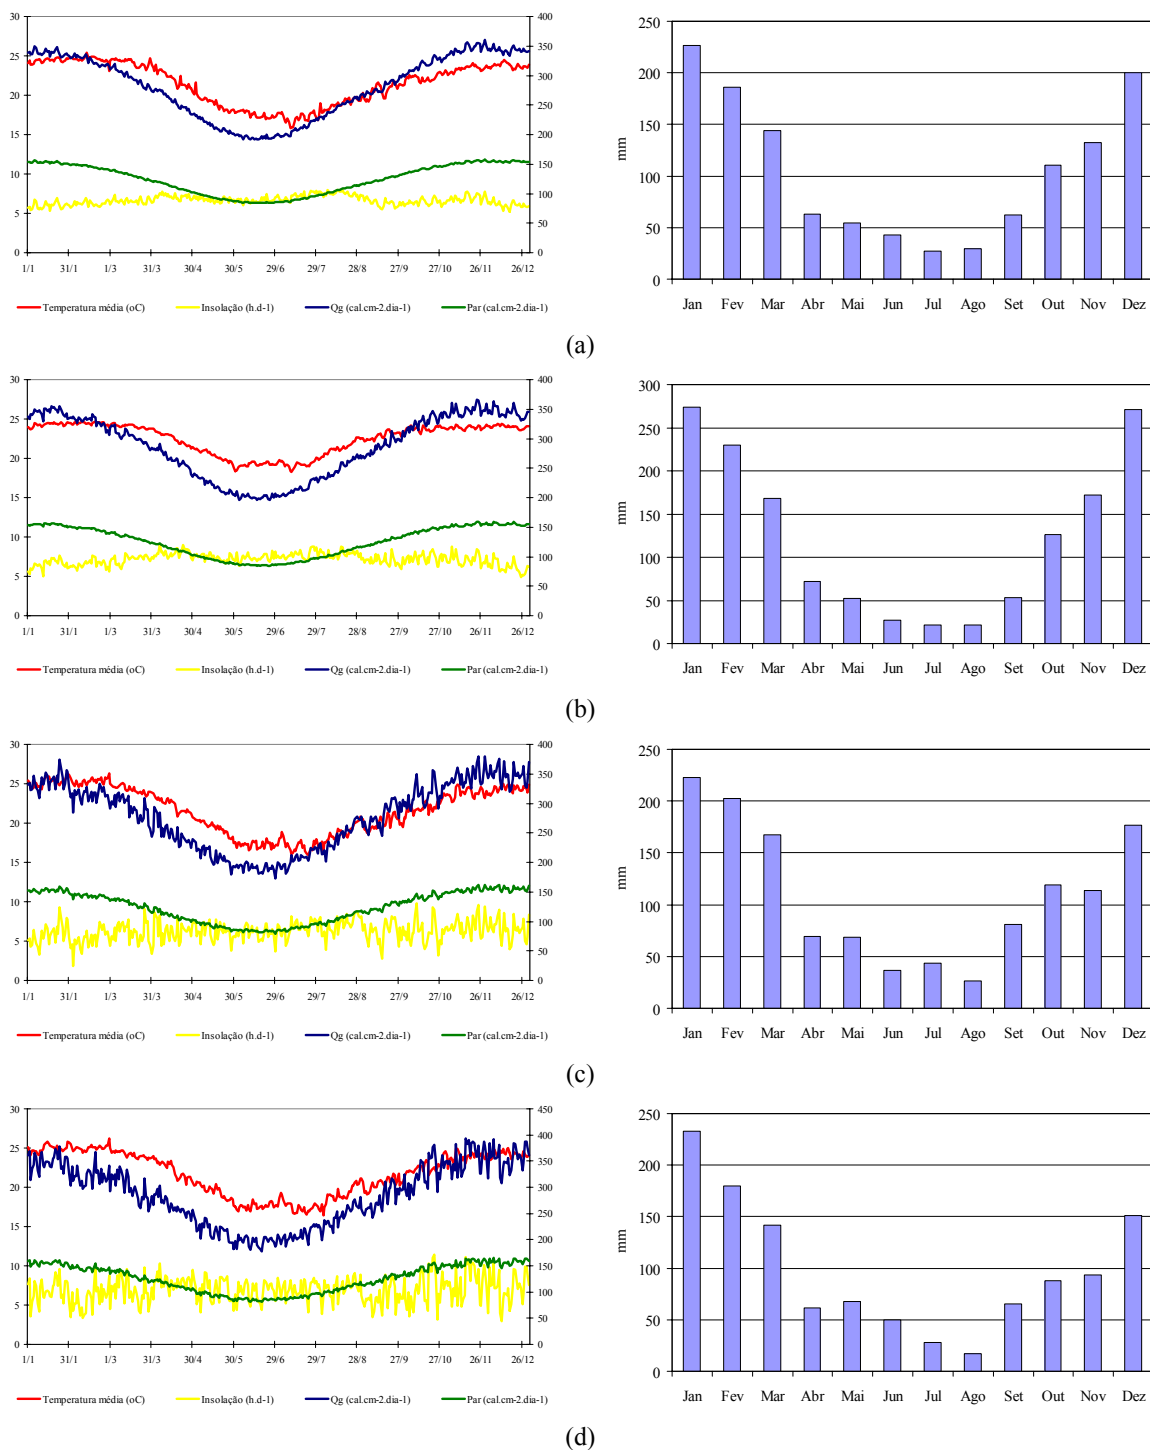


Figura 22 - Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h.d^{-1}), Irradiância Solar Global (Qg , $\text{cal.cm}^{-2}.\text{dia}^{-1}$), Radiação Fotossinteticamente Ativa (Par , $\text{cal.cm}^{-2}.\text{dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coleta de dados localizados nos municípios de Piracicaba (a), Riberão Preto (b), Tatuí (c) e Tietê (d)

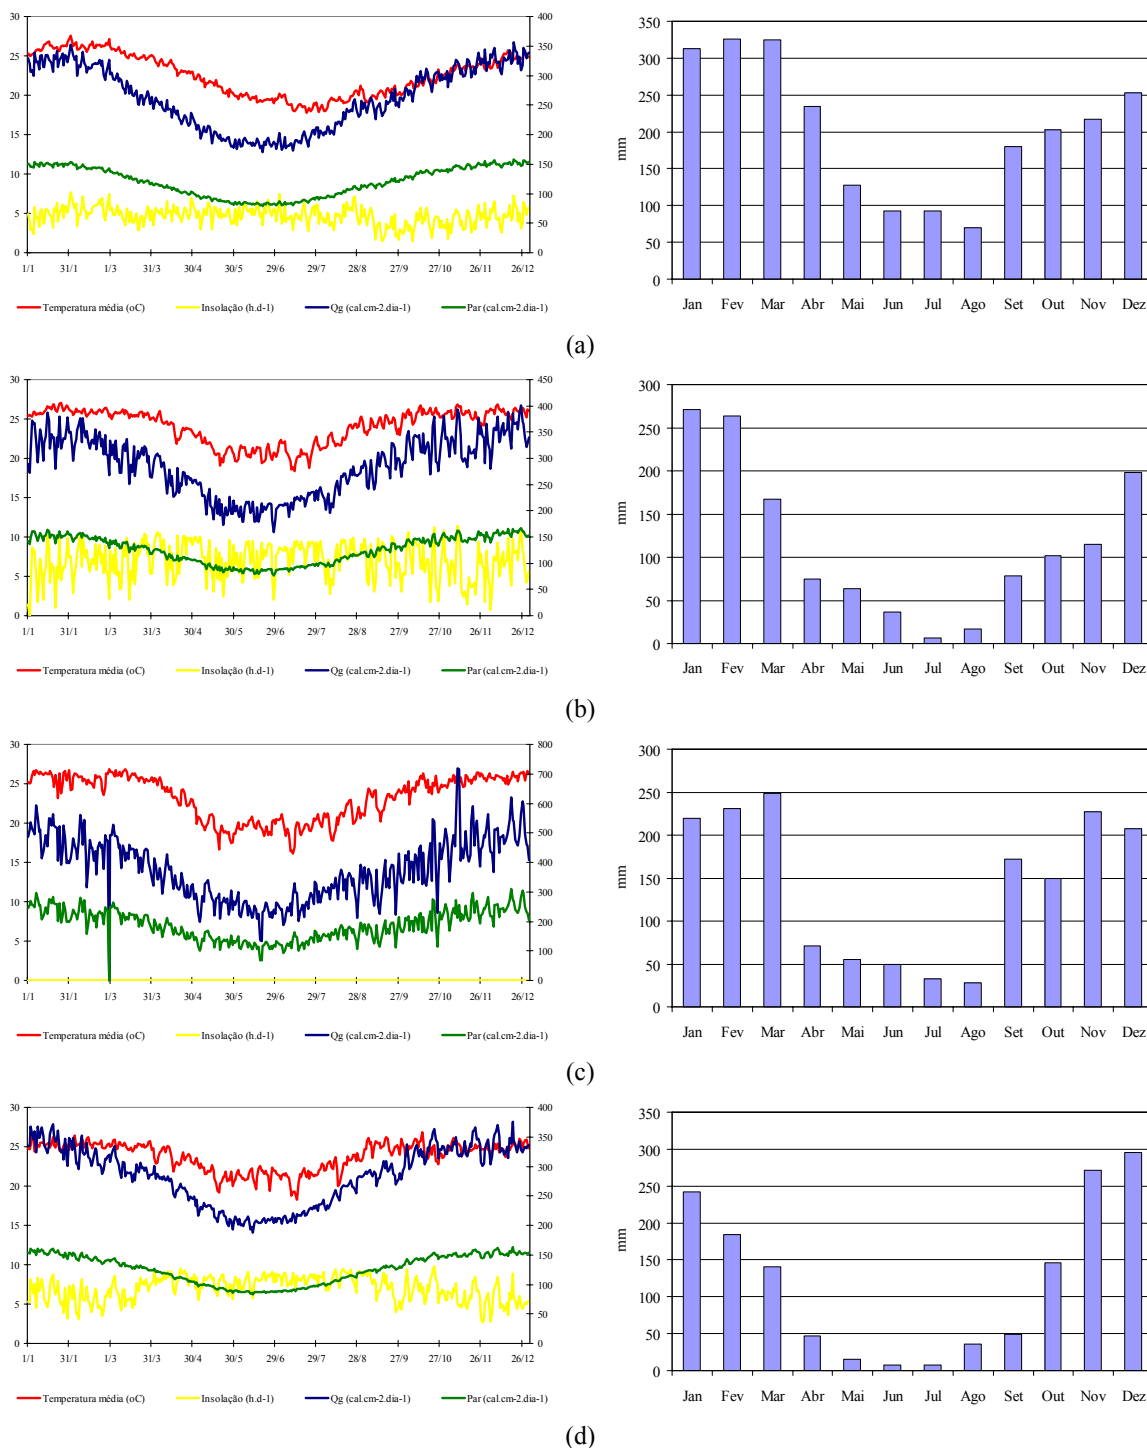


Figura 23 - Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insoiação (h.d^{-1}), Irradiância Solar Global (Qg , $\text{cal.cm}^{-2}.\text{dia}^{-1}$), Radiação Fotossinteticamente Ativa (Par , $\text{cal.cm}^{-2}.\text{dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coleta de dados localizados nos municípios de Votuporanga (a), Ubatuba (b), Guáira (c), Uberlândia (d)

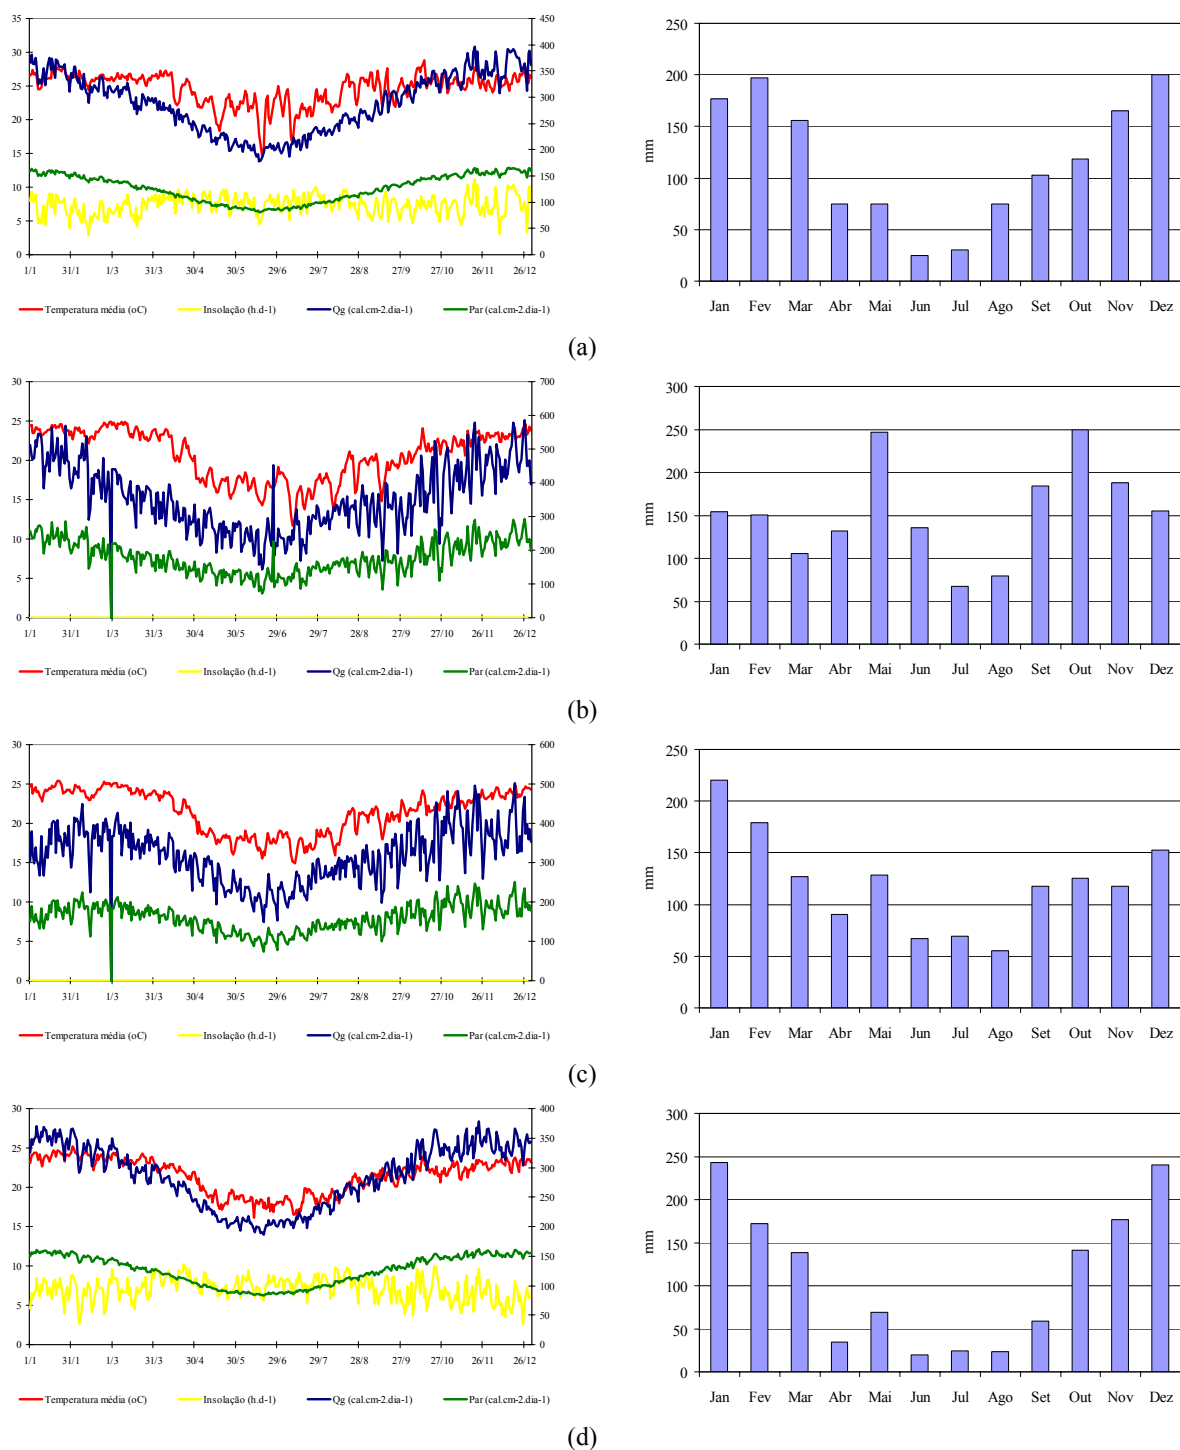


Figura 24 - Caracterização diária das variáveis climáticas temperatura média do ar ($^{\circ}\text{C}$), Insolação (h.d^{-1}), Irradiância Solar Global (Q_g , $\text{cal.cm}^{-2}.\text{dia}^{-1}$), Radiação Fotossinteticamente Ativa (Par , $\text{cal.cm}^{-2}.\text{dia}^{-1}$) e Precipitação média mensal (mm), para as estações convencionais de coleta de dados localizados nos municípios de Campo Grande (a), Cascavel (b), Londrina (c) e Lavras (d)

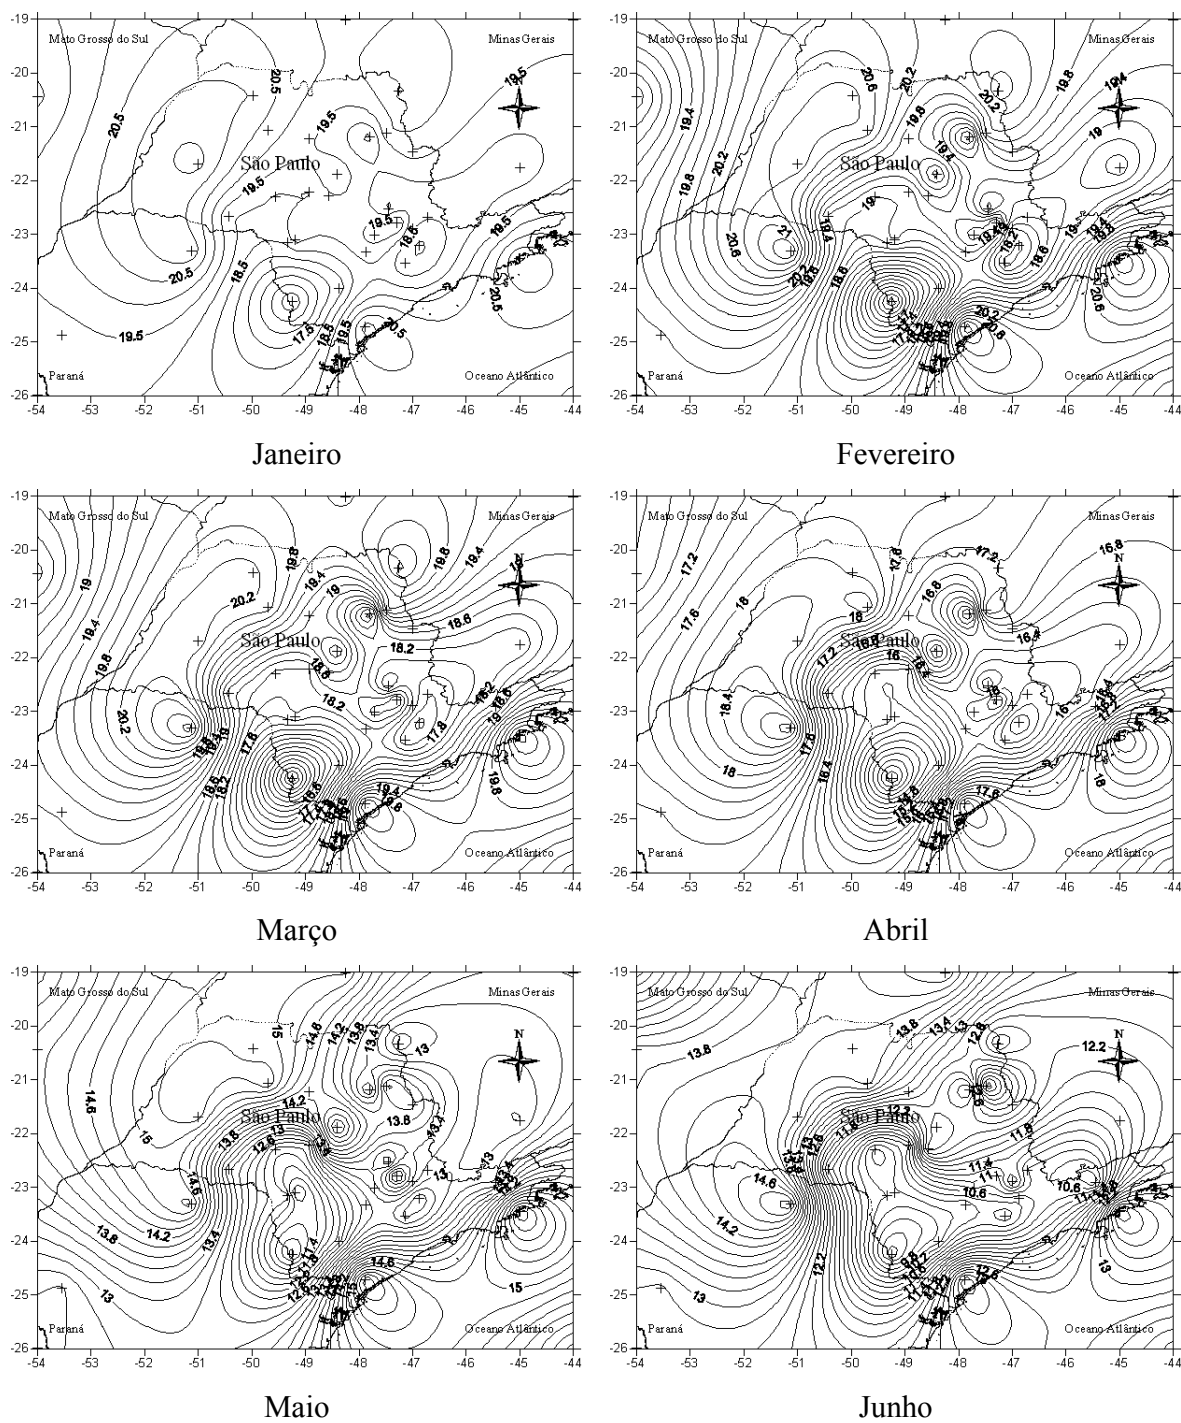


Figura 25 - Isolinhas de temperatura mínima média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo

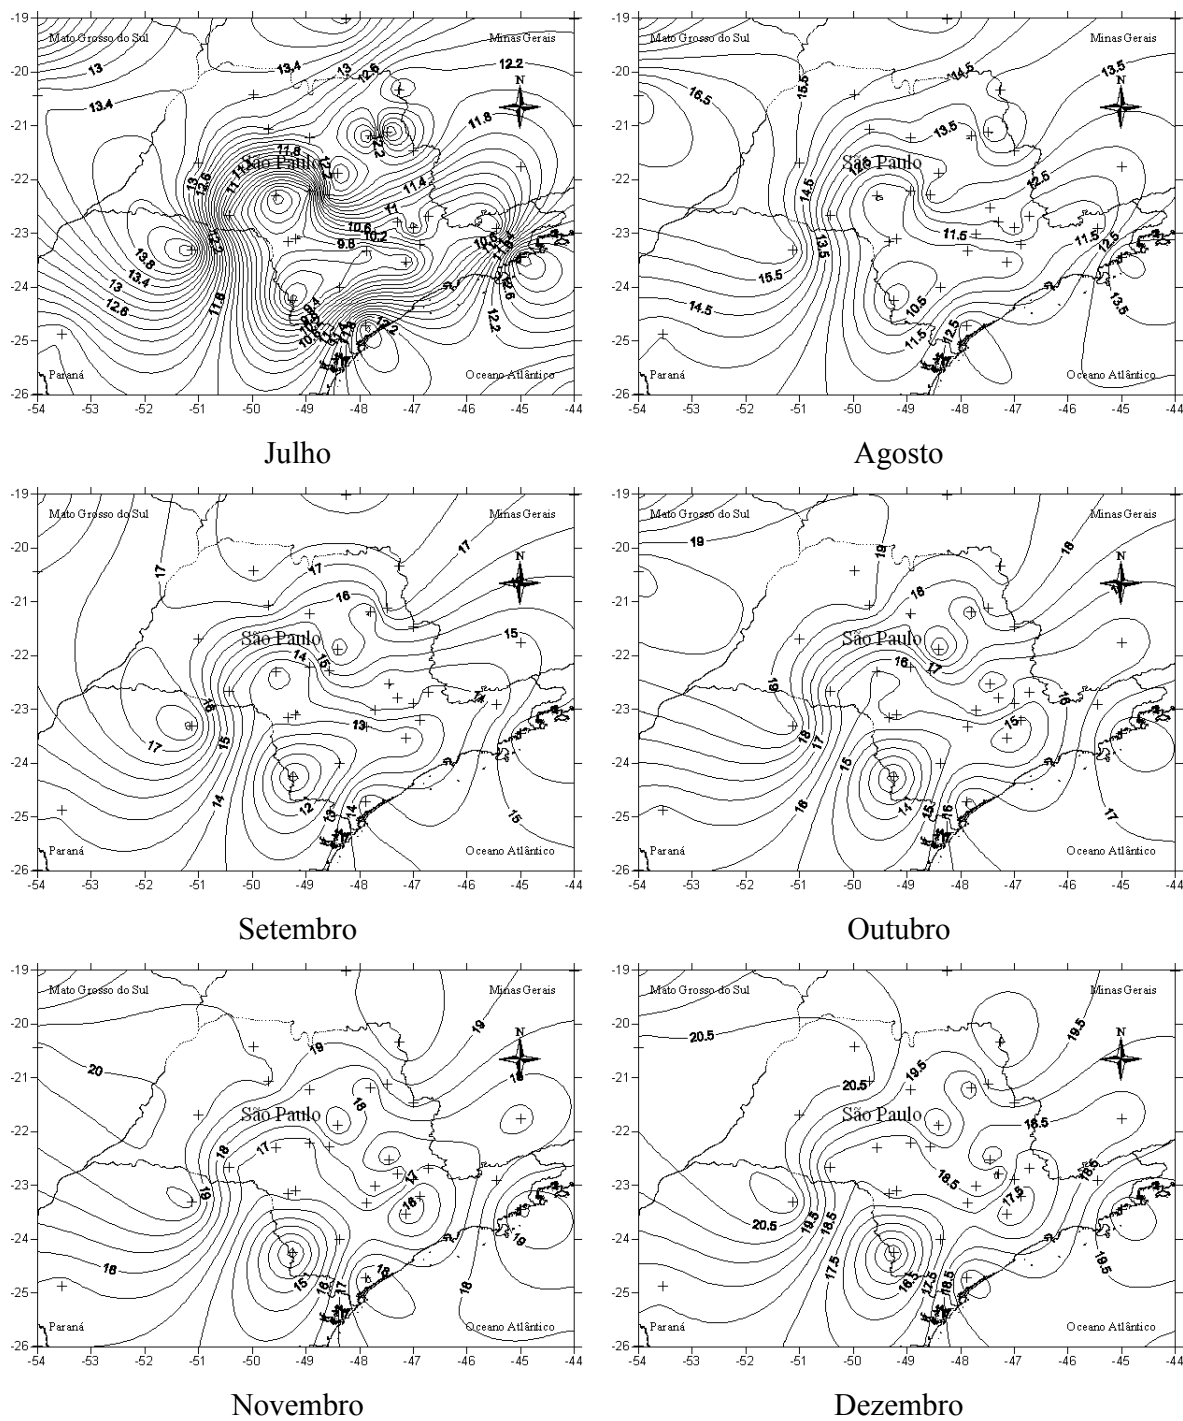


Figura 26 - Isolinhas de temperatura mínima média mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo

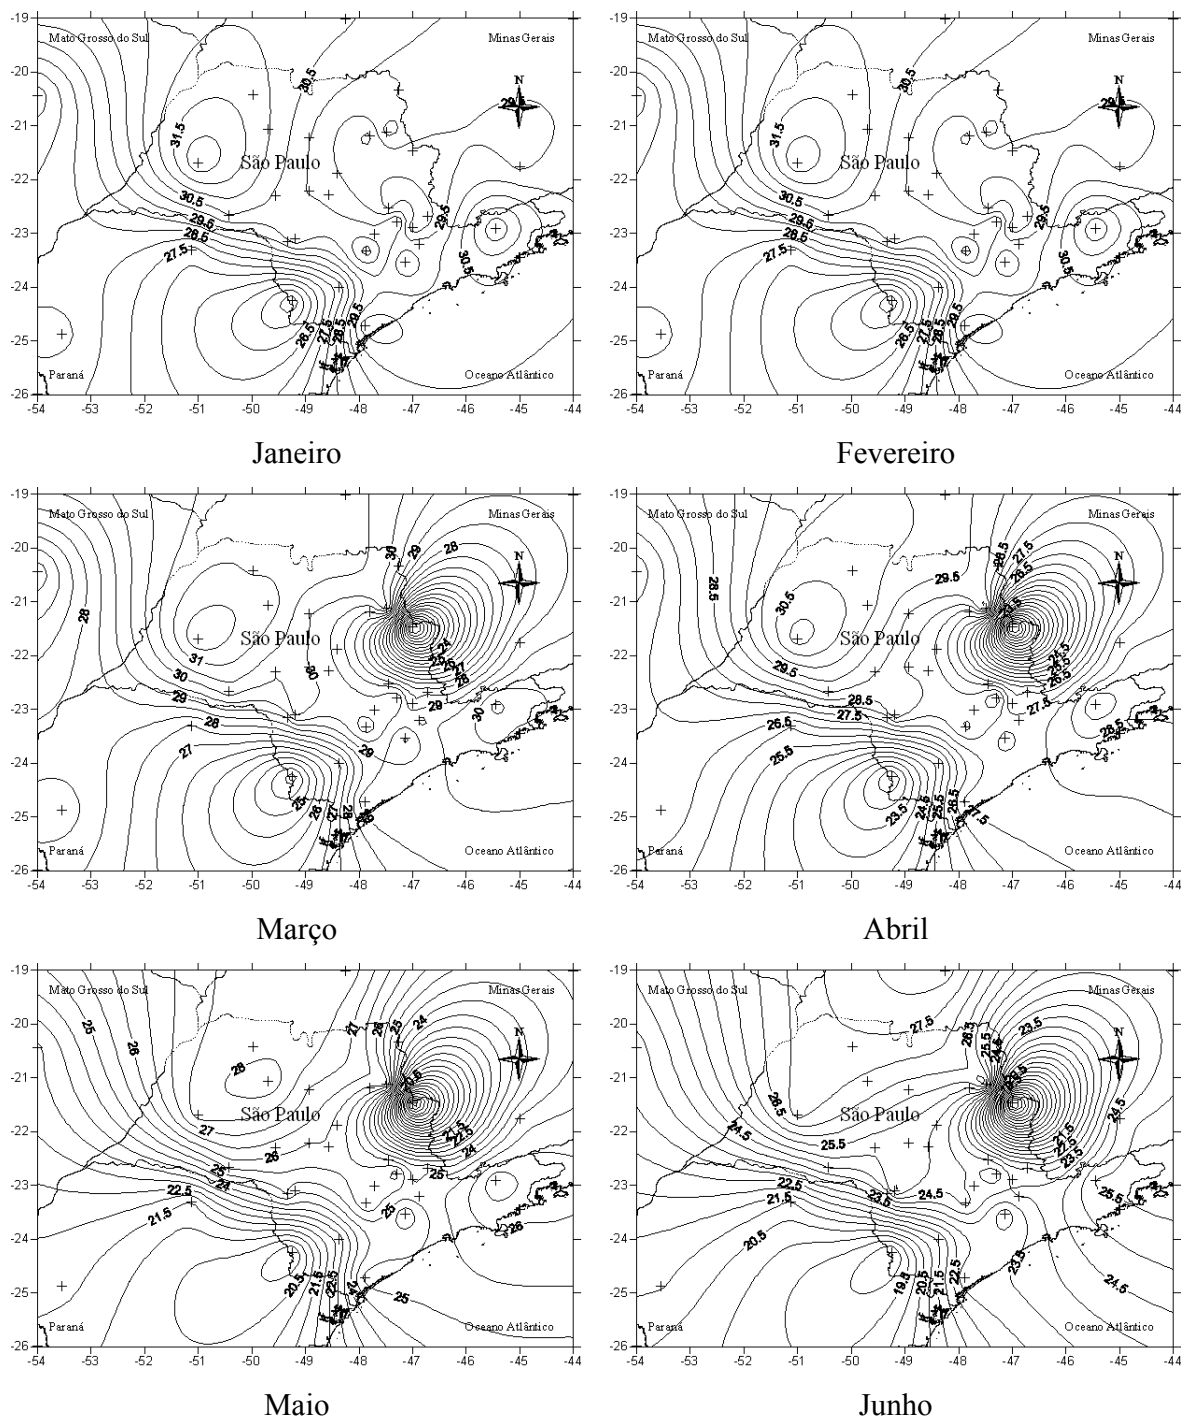


Figura 27 - Isolinhas de temperatura máxima média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo

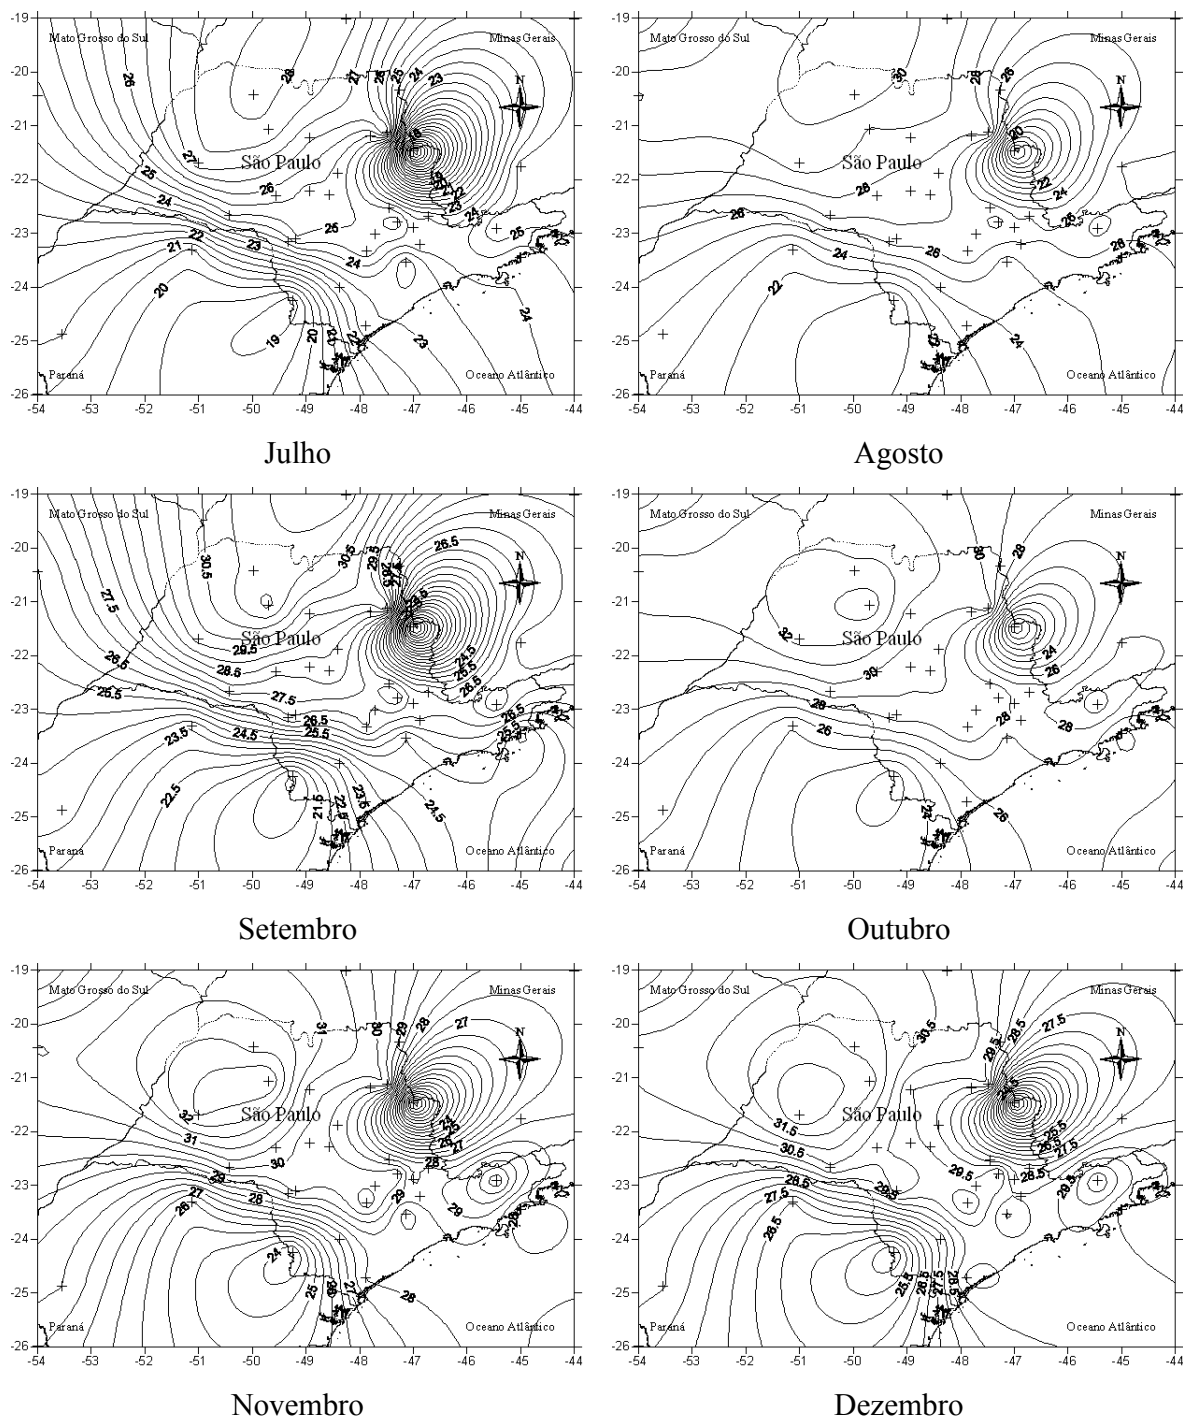


Figura 28 - Isolinhas de temperatura máxima média mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo

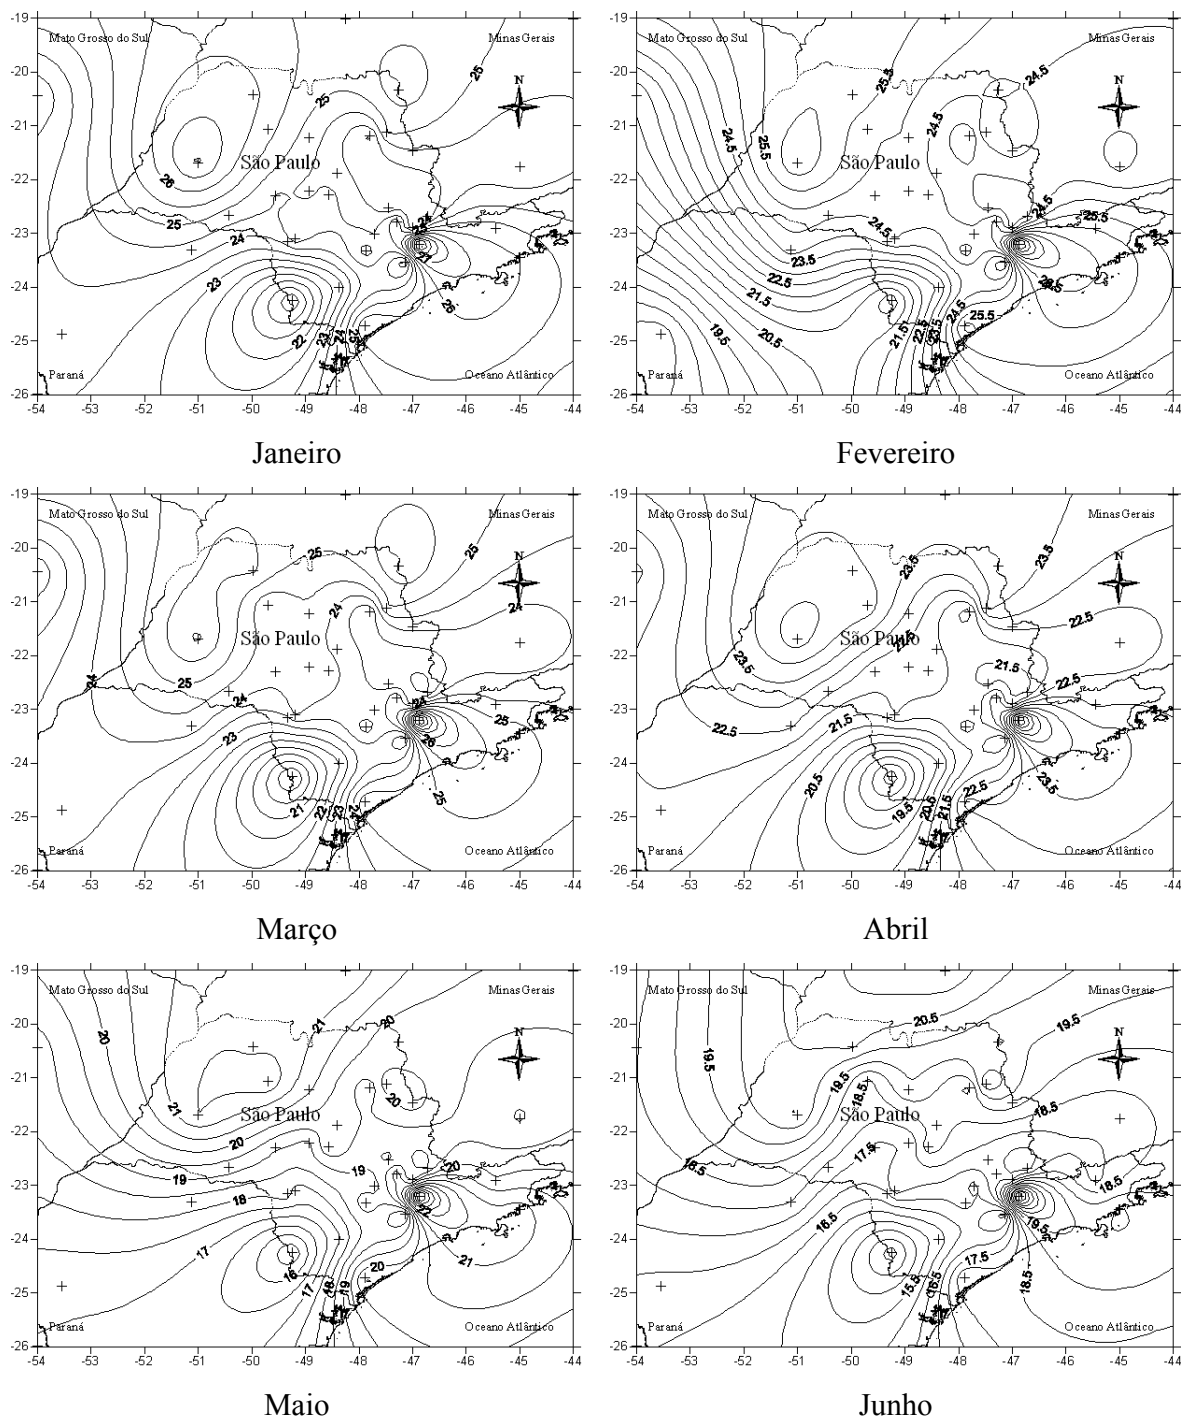


Figura 29 - Isolinhas de temperatura média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo

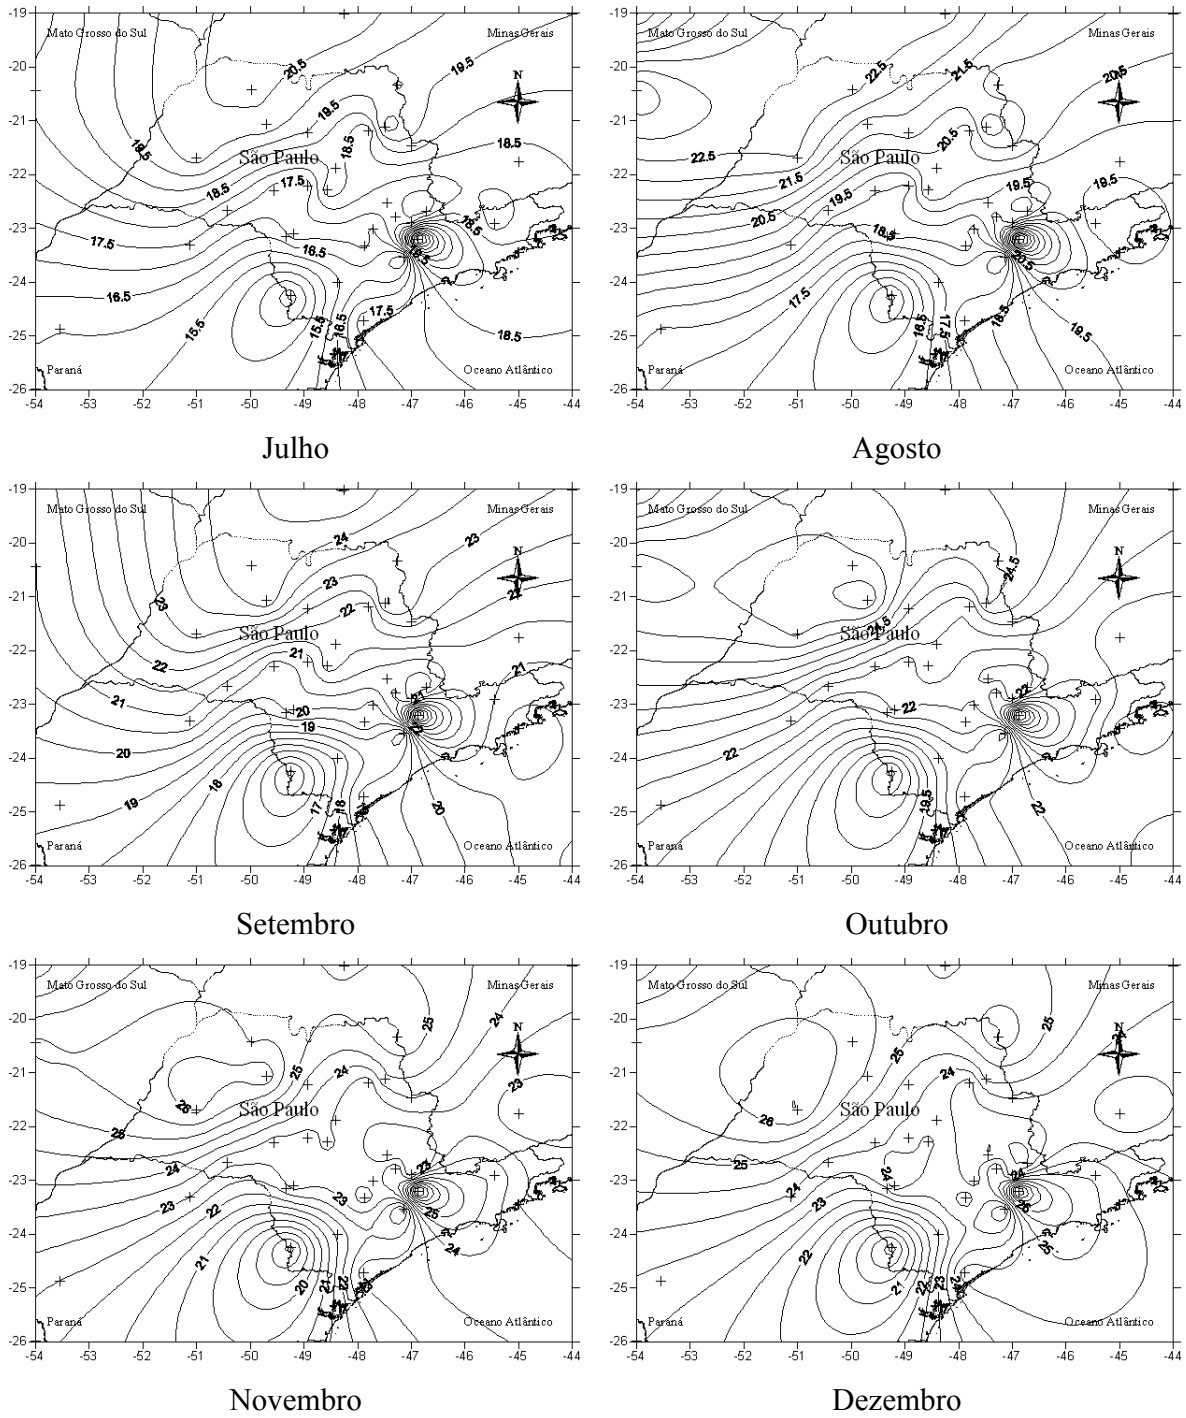


Figura 30 - Isolinhas de temperatura média mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo

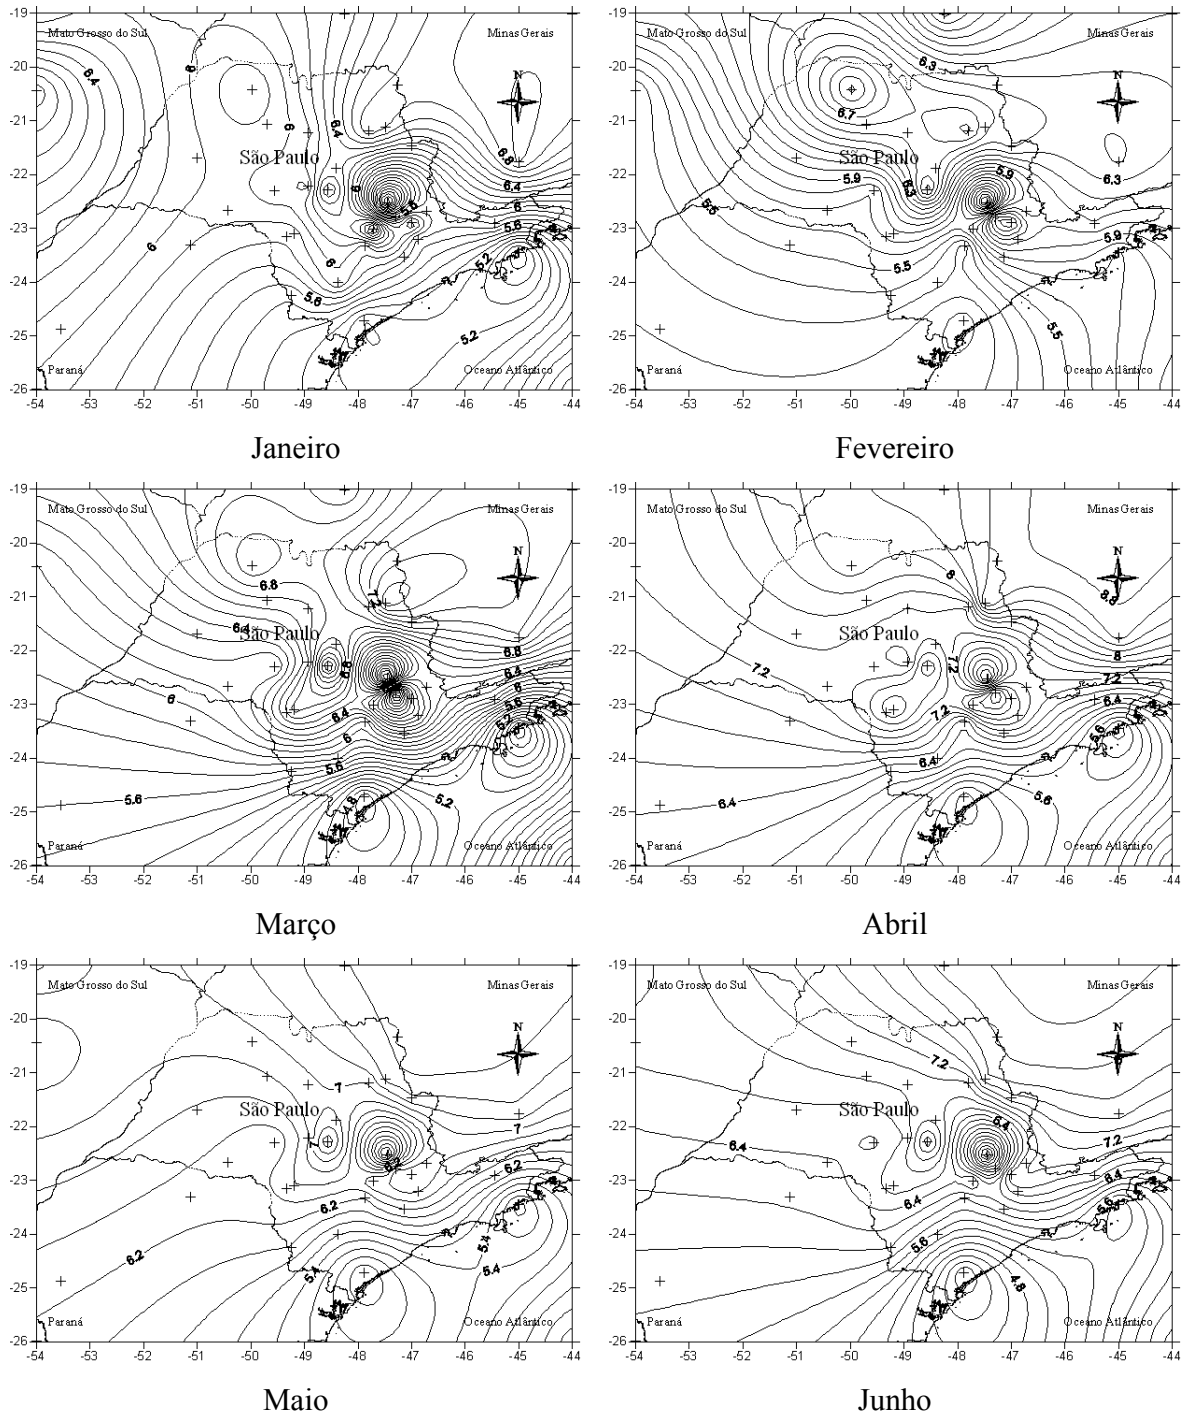


Figura 31 - Isolinhas de temperatura média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo

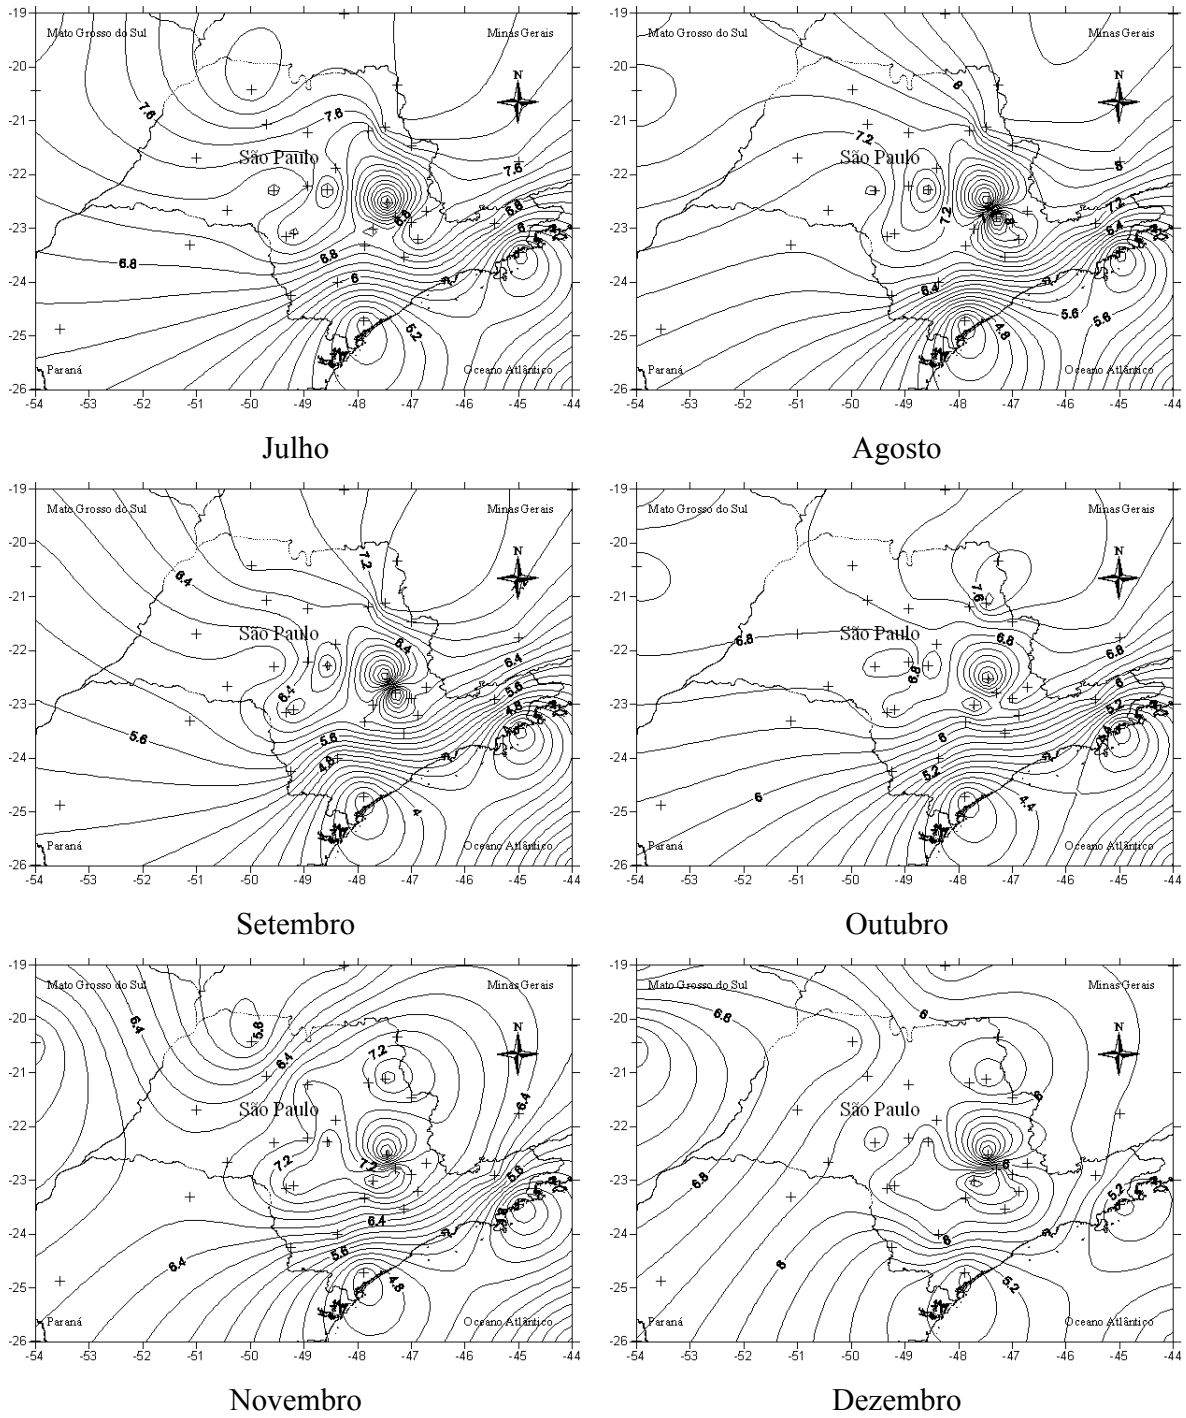


Figura 32 - Isolinhas de temperatura média mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo

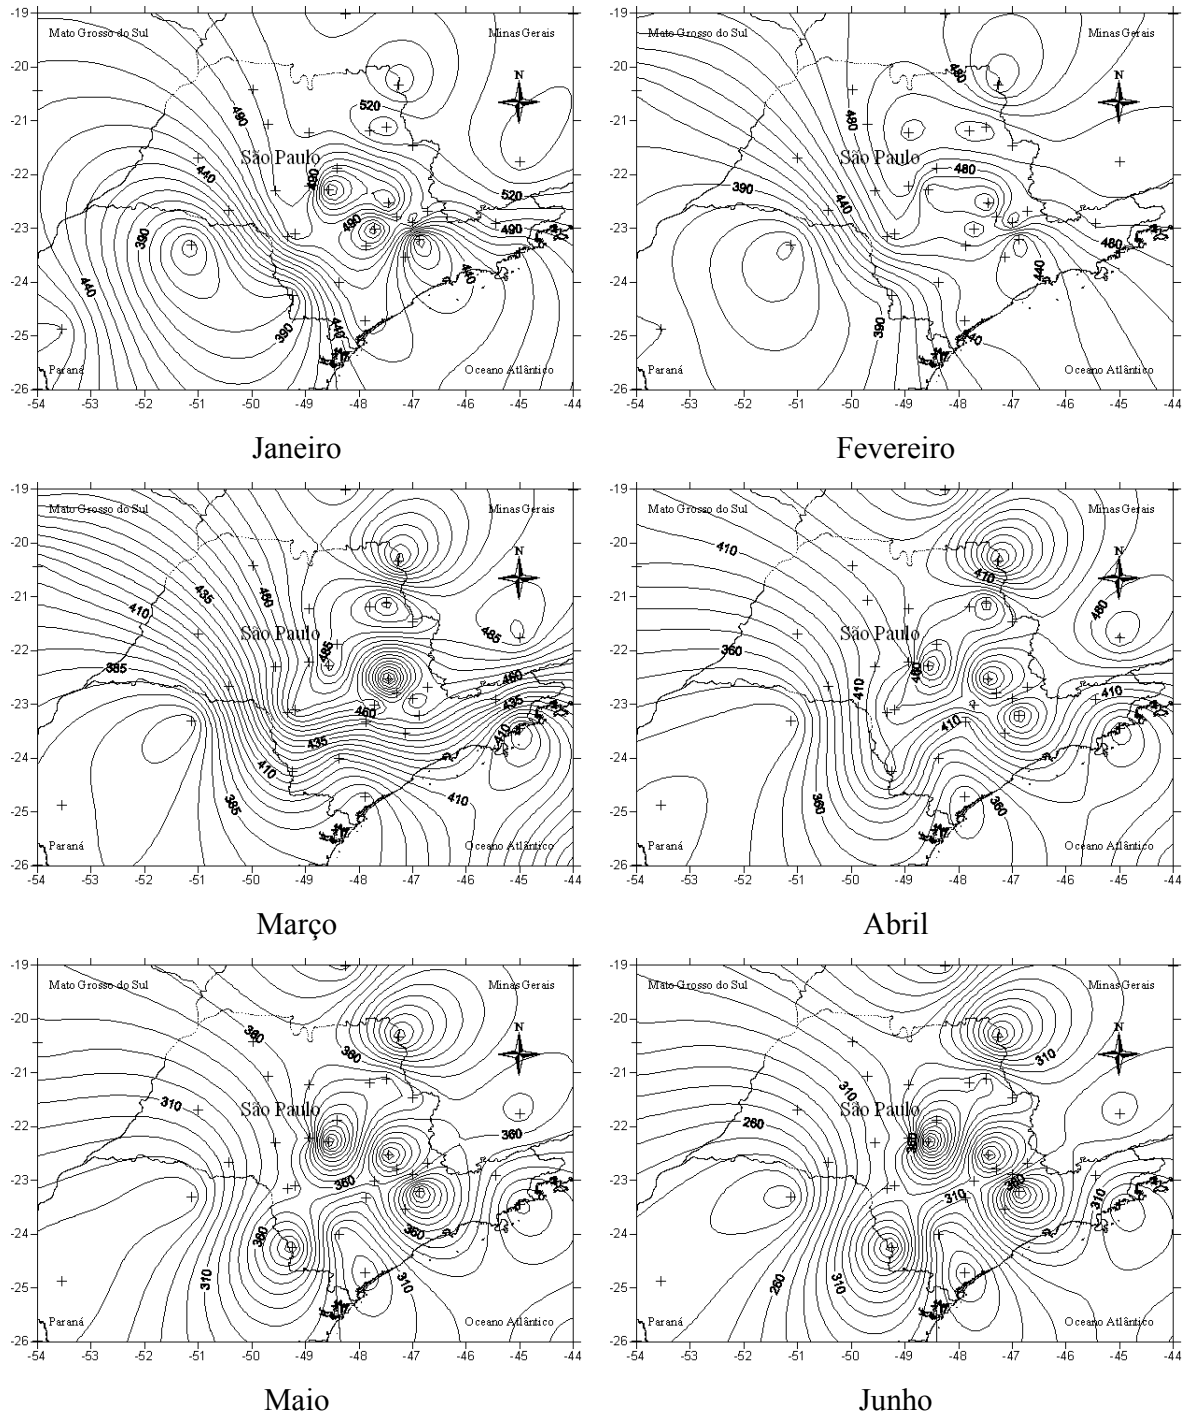


Figura 33 - Isolinhas de temperatura média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo

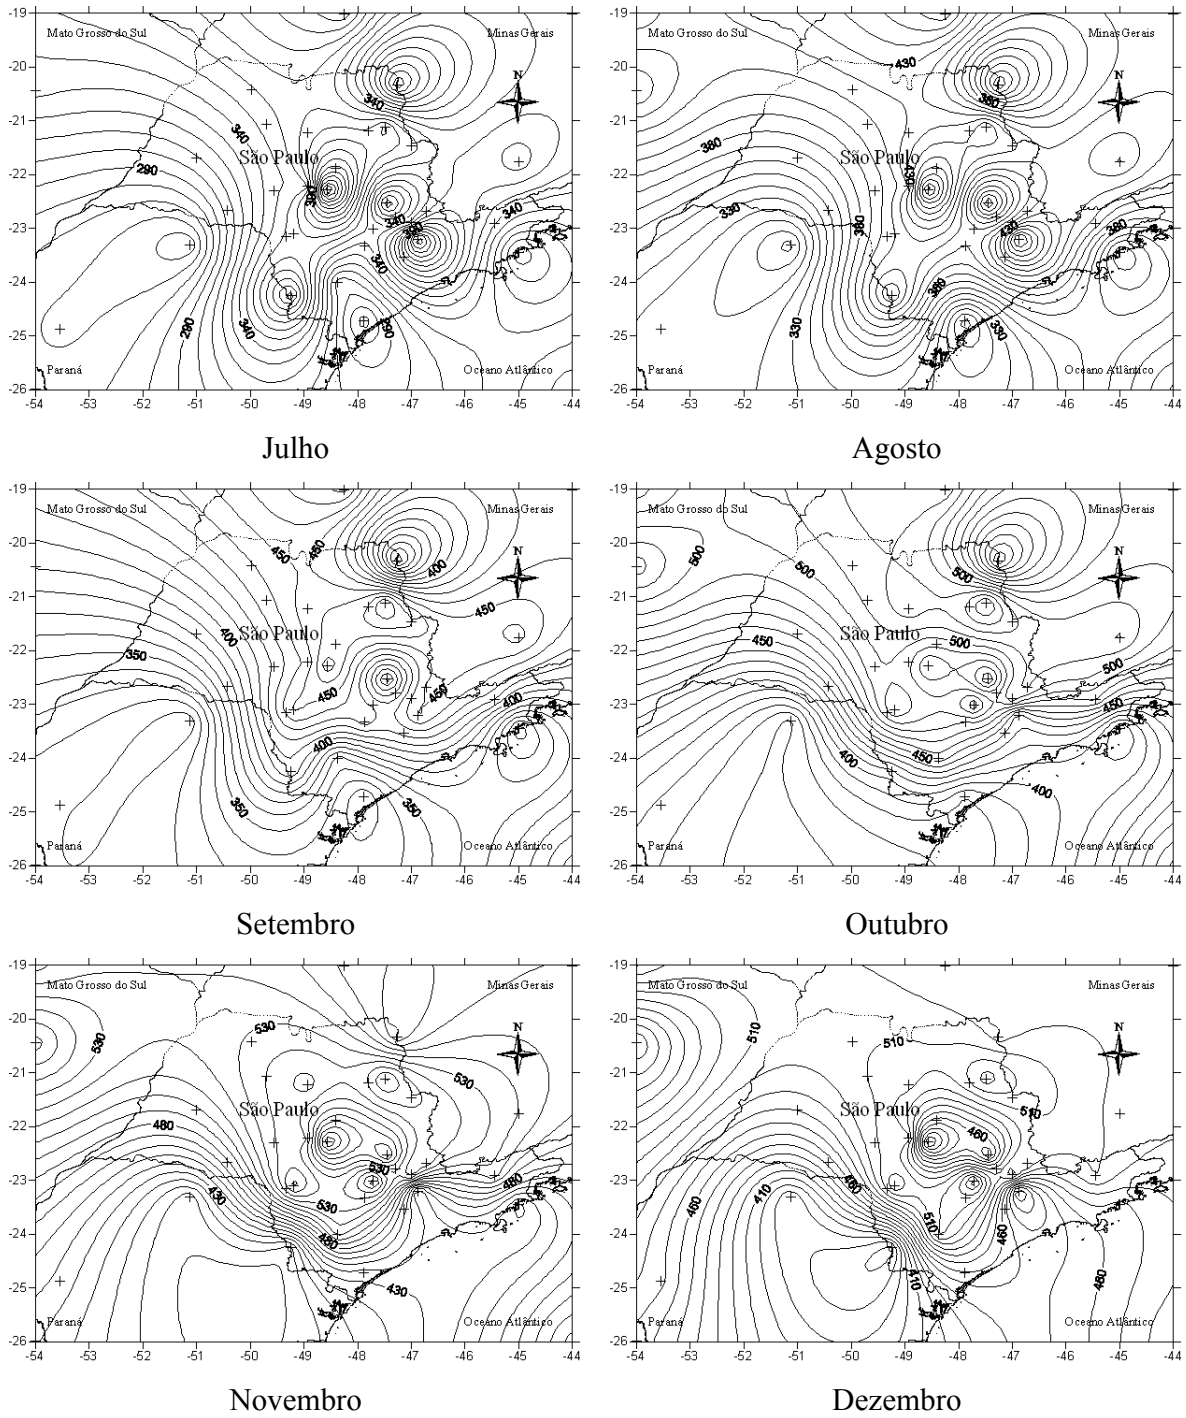


Figura 34 - Isolinhas de radiação solar global mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo

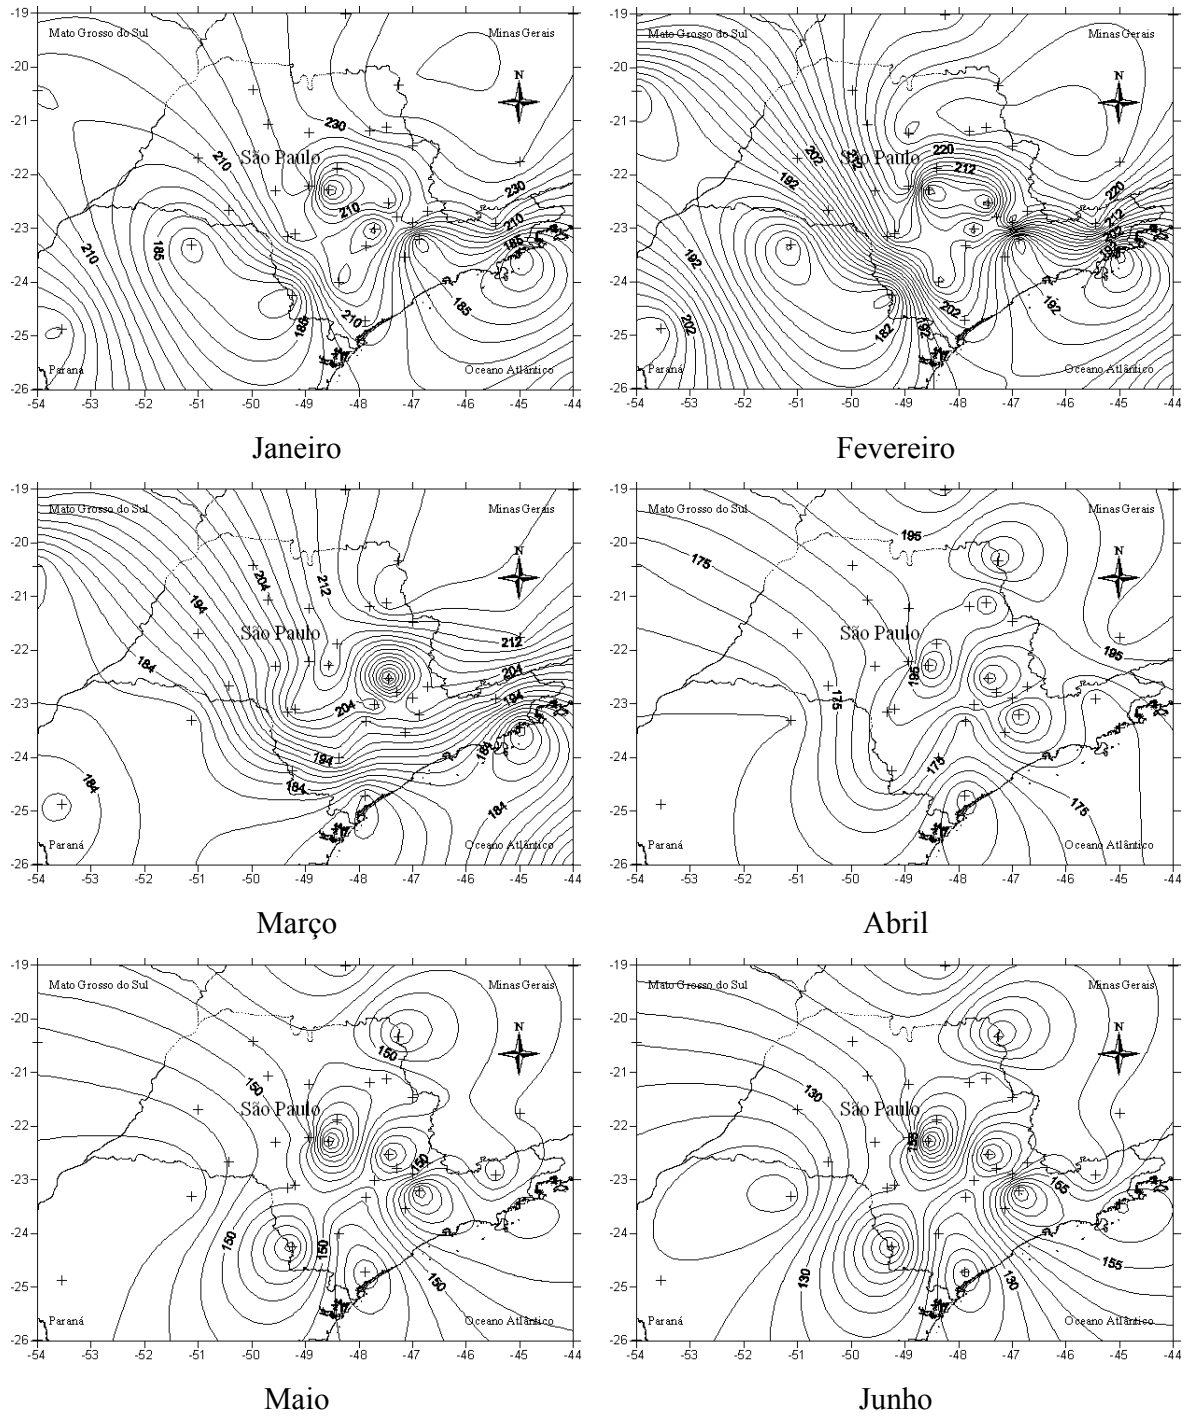


Figura 35 - Isolinhas de temperatura média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo

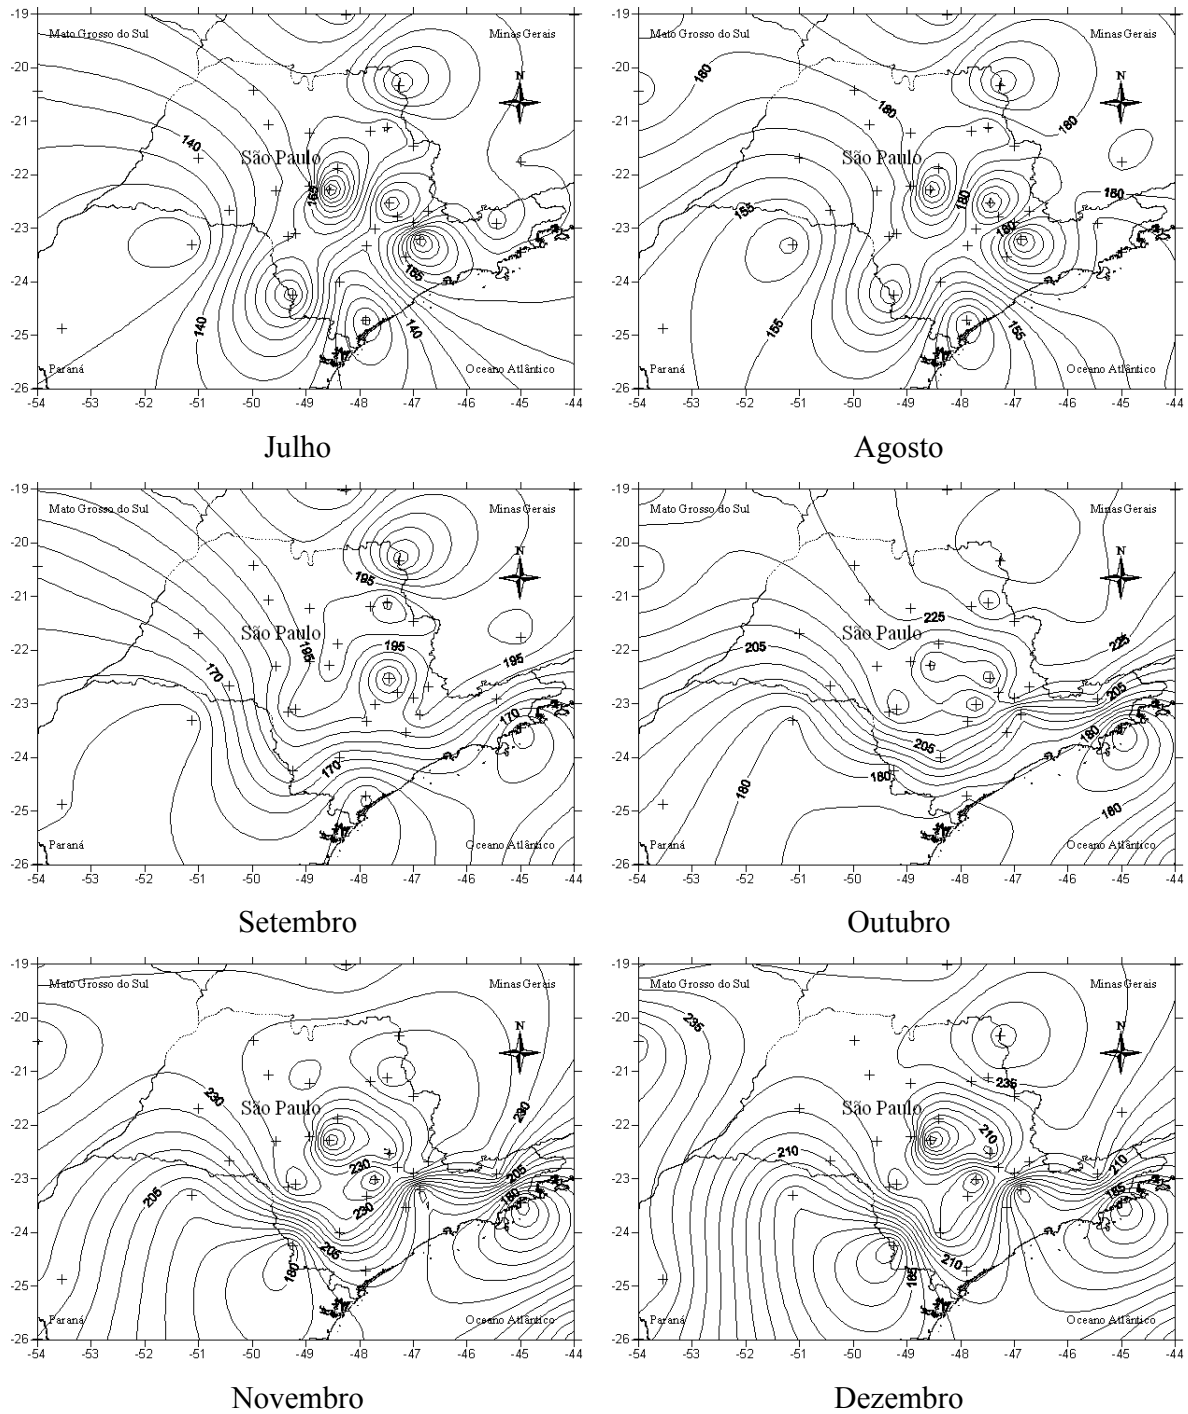
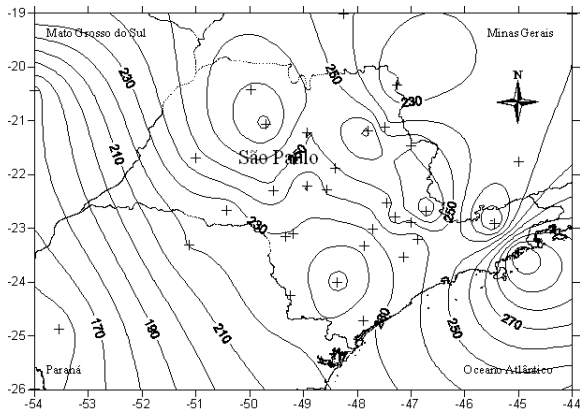
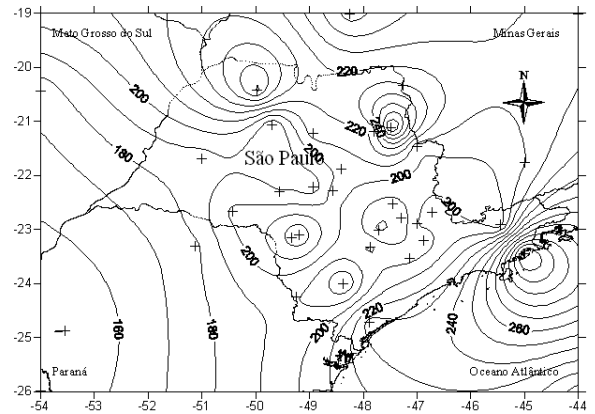


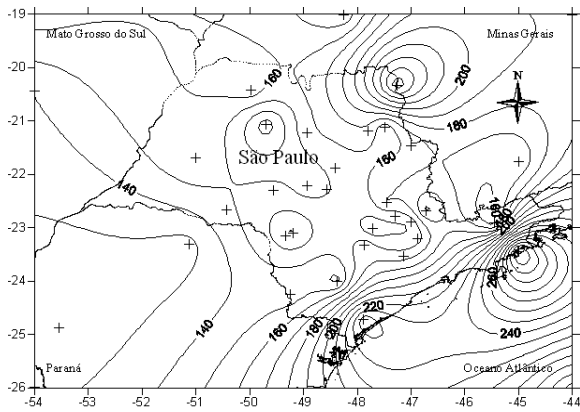
Figura 36 - Isolinhas de radiação solar global mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo



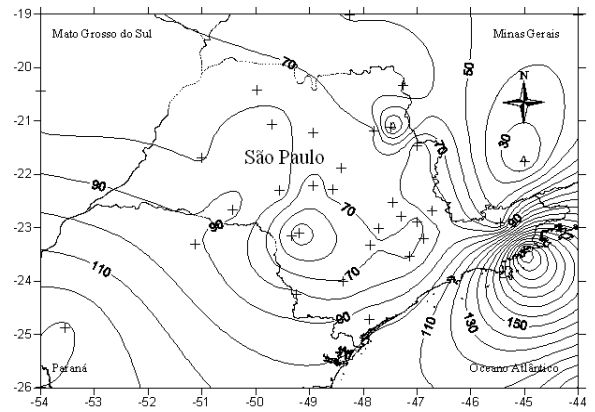
Janeiro



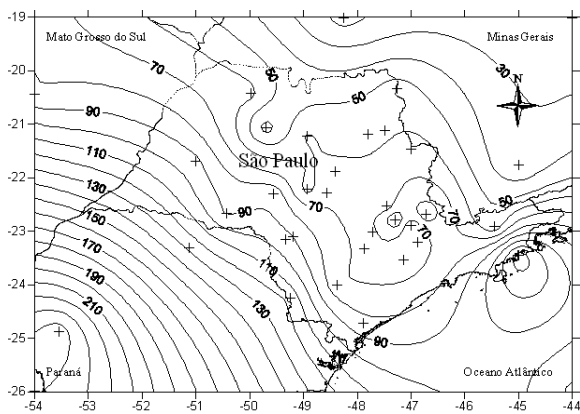
Fevereiro



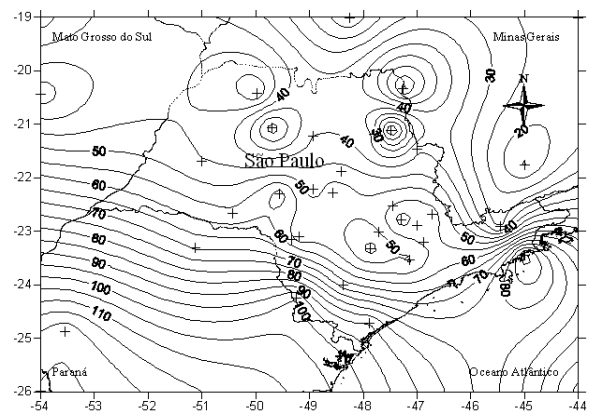
Março



Abril

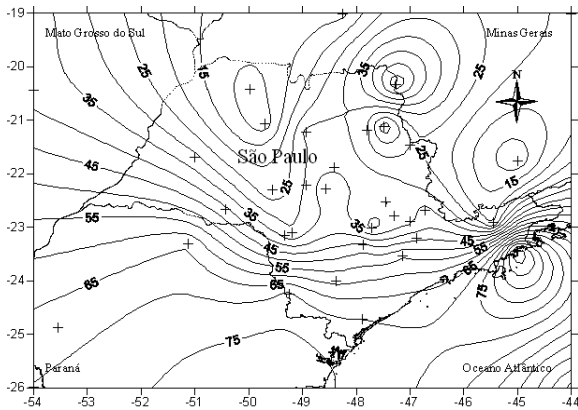


Maio

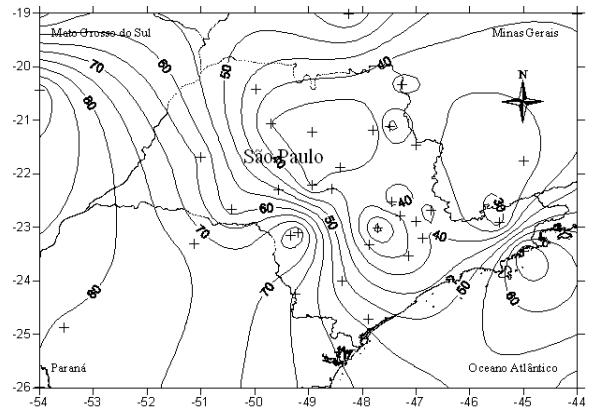


Junho

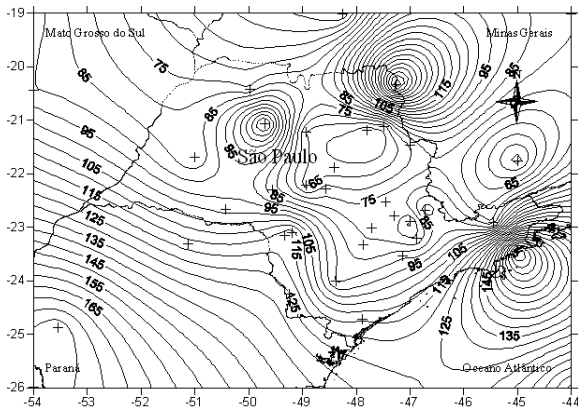
Figura 37 - Isolinhas da precipitação pluvial média mensal (janeiro a junho), devendo ser consideradas somente até os limites do Estado de São Paulo



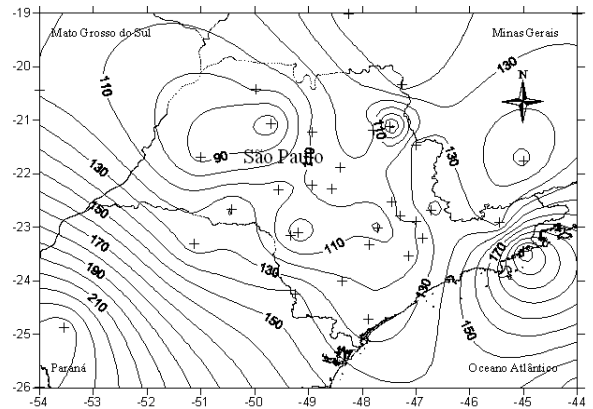
Julho



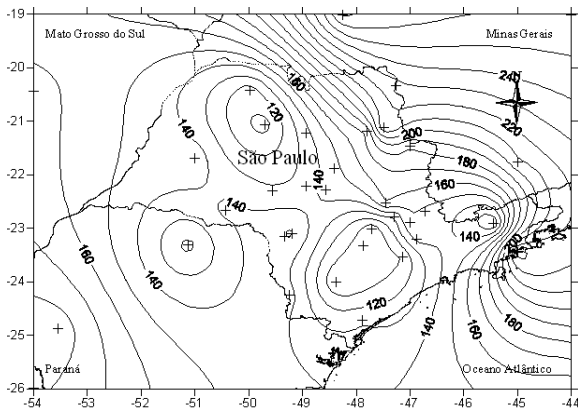
Agosto



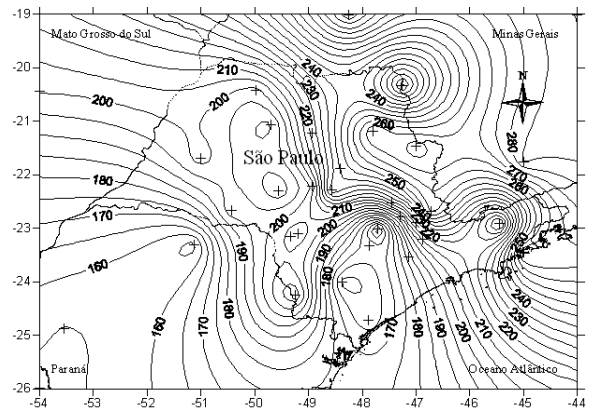
Setembro



Outubro



Novembro



Dezembro

Figura 38 - Isolinhas da precipitação pluvial média mensal (julho a dezembro), devendo ser consideradas somente até os limites do Estado de São Paulo

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)